

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE AUTOMAÇÃO E SISTEMAS**

Dayron Antonio Álvarez Rodríguez

**CONTROLE PREDITIVO PARA CADEIAS DE SUPRIMENTO NA
INDÚSTRIA DE PETRÓLEO, GÁS E BIOCOMBUSTÍVEIS**

Florianópolis

2016

Dayron Antonio Álvarez Rodríguez

**CONTROLE PREDITIVO PARA CADEIAS DE SUPRIMENTO NA
INDÚSTRIA DE PETRÓLEO, GÁS E BIOCOMBUSTÍVEIS**

Dissertação submetido ao Programa de Pós-
Graduação em Automação e Sistemas para
a obtenção do Grau de Mestre.

Orientador: Prof. Dr. Julio Elias Normey
Rico

Coorientador: Prof. Dr. Rodolfo César
Costa Flesch

Florianópolis

2016

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Álvarez, Dayron Antonio

Controle Preditivo para cadeias de suprimento na indústria de petróleo, gás e biocombustíveis / Dayron Antonio Álvarez ; orientador, Julio Elias Normey-Rico ; coorientador, Rodolfo César Flesch. - Florianópolis, SC, 2016.

113 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia de Automação e Sistemas.

Inclui referências

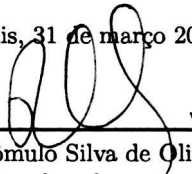
1. Engenharia de Automação e Sistemas. 2. Controle Preditivo Baseado em Modelos. 3. Cadeias de Suprimento. 4. Atraso de tempo. I. Normey-Rico, Julio Elias . II. Flesch, Rodolfo César . III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia de Automação e Sistemas. IV. Título.

Dayron Antonio Álvarez Rodríguez

**CONTROLE PREDITIVO PARA CADEIAS DE
SUPRIMENTO NA INDÚSTRIA DE PETRÓLEO, GÁS E
BIOCOMBUSTÍVEIS**

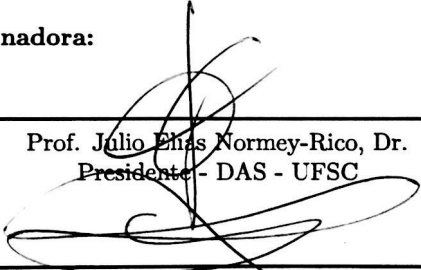
Esta Dissertação foi julgada aprovada para a obtenção do Título de “Mestre em Engenharia de Automação e Sistemas”, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Automação e Sistemas da Universidade Federal de Santa Catarina.

Florianópolis, 31 de março 2016.




Prof. Dr. Rômulo Silva de Oliveira
Coordenador


Banca Examinadora:



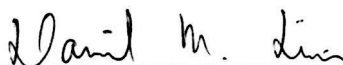
Prof. Julio Elias Normey-Rico, Dr.
Presidente - DAS - UFSC



Prof. Alejandro Hernan Gonzales, Dr.
Examinador - INTEC/CONICET - UNL



Prof. Eugenio de Bona Castelan Neto, Dr.
Examinador - DAS - UFSC



Prof. Daniel Martins Lima, Dr.
Examinador - DAS - UFSC

Dedicado a mis padres, nunca pudieron entender mis estudios pero siempre me enseñaron lo suficiente para enfrentar la vida.

AGRADECIMENTOS

A minha família.

Ao meu orientador Julio Elias Normey Rico e meu coorientador Rodolfo Flesch pela paciência, apoio, tempo e boa disposição que tiveram sempre na execução do trabalho.

Aos meus Amigos-Colegas-Conhecidos, que estiveram presentes em todos os momentos no LTIC.

RESUMO

Neste trabalho são abordados estudos de controle preditivo para o controle de estoques em cadeias de suprimentos. Uma cadeia de suprimento é um processo de fabricação integrado, em que as matérias-primas são convertidas em produtos finais entregues aos clientes. Processos de cadeias de suprimento podem ser matematicamente modelados, apresentando características de atraso de tempo, muitas vezes elevado, e dinâmicas integradoras. O problema de fato com o atraso são as limitações físicas, que não permitem que produtos sejam produzidos ou entregues até o decorrer dos tempos de atraso após a recepção dos pedidos. São tempos de espera presentes na dinâmica do modelo. O controle preditivo oferece flexibilidade em termos de troca de informação, topologias de rede e manipulação de restrições. Além disso, o controle preditivo trabalha sob otimização de objetivos. Objetivos que podem ser projetados para considerar informações econômicas, como também levar em conta objetivos mais comuns da teoria de controle, como rastreamento de referências, e especificações dinâmicas de suas variáveis. Dessa maneira, o problema pode ser escalado para manter níveis de estoque dentro de certos valores pré-determinados e, ao mesmo tempo, proporcionar um funcionamento economicamente ideal no processo de fabricação; em outras palavras, evitar mudanças rápidas no ritmo de produção e, ao mesmo tempo, evitar quantidades indesejáveis de produtos em estoque. Assim, foram desenvolvidas duas estratégias de controle, sendo a primeira baseada no controlador preditivo generalizado conhecido como GPC. A segunda estratégia de controle utilizada neste trabalho consistiu no aproveitamento da estrutura de compensação de atraso no preditor do GPC, implementando o algoritmo conhecido como DTC-GPC. Foram realizados ensaios de simulação usando coordenações centralizada e descentralizada dos controladores, funcionando em condições ideais e sob a presença de perturbações e incertezas. Os resultados obtidos mostram que os controladores DTC-GPC podem ter um impacto significativo e positivo sobre o controle dos níveis de estoque e, ao mesmo tempo, satisfazer as demandas do mercado.

Palavras-chave: Controle Preditivo Baseado em Modelo. Cadeias de Suprimento. Atraso de tempo.

ABSTRACT

This work addressed predictive control studies for inventory control in supply chains. A supply chain is an integrated manufacturing process, in which raw materials are converted into finished products delivered to customers. Supply chain processes can be mathematically modeled, using integrative models with delay time. The real problem with the delay are the physical limitations that do not allow products to be produced or delivered instantaneously by the course of the delay times of receipt of applications. Moreover, waiting times are present in the dynamic model. The model predictive control provides flexibility in terms of information exchange, network topologies and handling constraints. Moreover, the predictive control works under optimization goals. Goals that can be designed to consider economic aspects, but also take into account the most common goals of control theory, such as tracking references, and dynamic specifications of its variables. Thus, the problem can be scaled to keep inventory levels within certain predetermined values while at the same time provide an economically optimal operation in the manufacturing process; in other words, to avoid rapid changes in the production rate and, at the same time avoid undesirable amounts of products in stock. Thus, we developed two control strategies, the first based on generalized predictive controller known as GPC. The second control strategy used in this work uses a different delay compensation structure in the GPC predictor, implementing the algorithm known as DTC-GPC. Simulation tests were performed using centralized and decentralized coordination of the controllers, operating in ideal conditions and in the presence of disturbances and uncertainties. The results show that DTC-GPC controllers can have a significant and positive impact on the control of inventory levels and at the same time, satisfy the demands of the market.

Keywords: Model Predictive Control. Supply Chains. Dead-time.

SUMÁRIO

Lista de Figuras	
Lista de Tabelas	
Lista de Abreviaturas e Siglas	
1	INTRODUÇÃO
1.1	GESTÃO DE CADEIAS DE SUPRIMENTO
1.2	MOTIVAÇÃO
1.2.1	Setor Petrolífero no Brasil
1.2.2	Etanol a partir de Biomassa
1.2.3	Gestão de cadeias de suprimento mediante MPC
1.3	OBJETIVOS
1.4	ESTRUTURA DA DISSERTAÇÃO
2	TEORIA DE CONTROLE EM CADEIAS DE SUPRIMENTO 31
2.1	PROBLEMÁTICA
2.2	MODELOS DE CADEIA DE SUPRIMENTO
2.2.1	Modelagem Matemática
2.2.2	Especificações típicas para Controle
2.3	CONTROLE DE CADEIAS DE SUPRIMENTO NA LITE- RATURA
2.4	COMENTÁRIOS FINAIS DO CAPÍTULO
3	CONTROLE PREDITIVO (MPC)
3.1	CONCEITOS BÁSICOS DE CONTROLE PREDITIVO BASEADO EM MODELO (MPC)
3.2	ESTRUTURA BÁSICA DOS CONTROLADORES PREDI- TIVOS
3.2.1	Modelo de predição
3.2.2	Função custo
3.2.3	Cálculo da lei de controle
3.2.4	Metodologia dos controladores preditivos
3.3	CONTROLE PREDITIVO GENERALIZADO (GPC), SISTEMAS MONOVARIÁVEIS
3.4	USO DE RESTRIÇÕES
3.5	GPC PARA SISTEMAS COM ATRASO DE TEMPO (DTC- GPC)
3.5.1	Compensação antecipativa
3.6	EXTENSÃO PARA O CASO MULTIVÁRIAVEL
3.7	COMENTÁRIOS FINAIS DO CAPÍTULO
4	ESTRATÉGIAS DE CONTROLE

4.1	SISTEMA CLÁSSICO DE ESTOQUE	63
4.1.1	Resultados do GPC no caso nominal	64
4.1.2	Resultados do GPC sob incertezas	66
4.1.3	Resultados do DTC-GPC sob incertezas	67
4.2	EXEMPLO DE CADEIA DE SUPRIMENTOS	68
4.2.1	Estruturas de coordenação das cadeias de suprimento	68
4.2.2	Formulação do problema	69
4.2.3	Coordenação centralizada	70
4.2.3.1	Resultados do controlador GPC no caso nominal	70
4.2.3.2	Resultados do controlador GPC sob incertezas	72
4.2.3.3	Resultados do controlador DTC-GPC sob incertezas	73
4.2.4	Coordenação descentralizada	74
4.2.4.1	Resultados do controlador GPC no caso nominal	75
4.2.4.2	Resultados do controlador GPC sob incertezas	77
4.2.4.3	Resultados do controlador DTC-GPC sob incertezas	77
4.3	COMENTÁRIOS FINAIS DO CAPÍTULO	79
5	ESTUDOS DE CASO	81
5.1	ESTUDO EM PETRÓLEO E GÁS	81
5.1.1	Sistema de Refino	81
5.1.2	Formulação do problema	82
5.1.3	Resultados de simulação	86
5.2	ESTUDO EM BIOCOMBUSTÍVEIS	93
5.2.1	Esquema de sustentabilidade	93
5.2.2	Formulação do problema	94
5.2.3	Resultados de simulação	97
5.3	COMENTÁRIOS FINAIS DO CAPÍTULO	100
6	CONCLUSÕES	103
6.1	SUGESTÕES PARA TRABALHOS FUTUROS	104
	REFERÊNCIAS	107

LISTA DE FIGURAS

Figura 1.1	Diagrama simples da Cadeia de Suprimentos	22
Figura 1.2	Cadeia de Suprimentos de Petróleo e Gás Natural	23
Figura 2.1	Tempos de produção e transporte na CS	32
Figura 2.2	CS simplificada de três estágios	35
Figura 2.3	Diagrama de blocos do modelo simplificado da rede de CS .	36
Figura 3.1	Estrutura básica do MPC	42
Figura 3.2	Metodologia do MPC	45
Figura 3.3	Resposta livre	50
Figura 3.4	Resposta Forçada	51
Figura 3.5	Estrutura de controle do GPC	56
Figura 3.6	Estrutura do DTC-GPC com ação antecipativa	59
Figura 4.1	Analogia de fluidos para um sistema clássico de estoque. . . .	64
Figura 4.2	Resultados do controlador GPC desconsiderando erros na modelagem e na previsão de demanda	65
Figura 4.3	Resultados do controlador GPC considerando erros na mode- lagem e na previsão de demanda	66
Figura 4.4	Resultados do controlador DTC-GPC considerando erros na modelagem e na previsão de demanda	68
Figura 4.5	Analogia de fluidos na estratégia de controle centralizado. . .	70
Figura 4.6	Resultados de simulação GPC centralizado desconsiderando erros na modelagem e na previsão de demanda	71
Figura 4.7	Resultados de simulação GPC centralizado considerando er- ros na modelagem e na previsão de demanda	73
Figura 4.8	Resultados de simulação DTC-GPC centralizado considerando erros na modelagem e na previsão de demanda	74
Figura 4.9	Analogia de fluidos na estratégia de controle descentralizado.	75
Figura 4.10	Resultados de simulação GPC descentralizado desconsiderando erros na modelagem e na previsão de demanda	76
Figura 4.11	Resultados de simulação GPC descentralizado considerando erros na modelagem e na previsão de demanda	77
Figura 4.12	Resultados de simulação DTC-GPC descentralizado considerando erros na modelagem e na previsão de demanda	78
Figura 5.1	Esquema de controle descentralizado e mapeamento de vari-	

áveis do sistema de CS	83
Figura 5.2 Estoque de cru	90
Figura 5.3 Estoque de diesel	90
Figura 5.4 Estoque de gasolina	91
Figura 5.5 Estoque de nafta	91
Figura 5.6 Estoque de gás liquefeito de petróleo	92
Figura 5.7 Estoque de querosene de aviação	92
Figura 5.8 Fluxo de processos de açúcar, etanol e bio-electricidade	94
Figura 5.9 Esquema de controle centralizado e mapeamento de variáveis do sistema de CS	95
Figura 5.10 Estoque cana de açúcar	99
Figura 5.11 Cana de açúcar demandada	99
Figura 5.12 Nível de estoque de cana de açúcar	100
Figura 5.13 Bagaço demandado	100

LISTA DE TABELAS

Tabela 4.1	Parâmetros de ajuste do controlador GPC	65
Tabela 4.2	Restrições de operação SISO	65
Tabela 4.3	Parâmetros de ajuste do controlador DTC-GPC	67
Tabela 4.4	Restrições de operação MIMO	72
Tabela 4.5	Parâmetros de ajuste do controlador GPC centralizado	72
Tabela 4.6	Incertezas inseridas na modelagem	72
Tabela 4.7	Parâmetros de ajuste do controlador DTC-GPC centralizado	74
Tabela 4.8	Parâmetros de ajuste do controlador GPC descentralizado ..	76
Tabela 4.9	Parâmetros de ajuste do controlador DTC-GPC descentrali- zado	78
Tabela 5.1	Mapeamento de variáveis no controlador MISO	84
Tabela 5.2	Mapeamento de variáveis no controlador MIMO	84
Tabela 5.3	Dados de simulação do algoritmo LP	87
Tabela 5.4	Dados de simulação e estados iniciais na CS	87
Tabela 5.5	Incertezas inseridas na modelagem controlador DTC-GPC MIMO	88
Tabela 5.6	Parâmetros de ajuste do controlador MISO	88
Tabela 5.7	Parâmetros de ajuste do controlador MIMO	89
Tabela 5.8	Parâmetros de restrição controlador MISO	89
Tabela 5.9	Parâmetros de restrição controlador MIMO	89
Tabela 5.10	Mapeamento de variáveis no controlador	96
Tabela 5.11	Parâmetros de ajuste do controlador	97
Tabela 5.12	Dados de simulação e estados iniciais na CS	98
Tabela 5.13	Parâmetros de restrição	98

LISTA DE ABREVIATURAS E SIGLAS

CS Cadeia de Suprimento do inglês supply chain (SC)

DTC-GPC Generalized predictive control-Dead-time compensator

FSP Filtered smith predictor

GPC Generalized predictive control

LP Linear programming

MPC Model predictive Control

MIMO Multiple Input-Multiple Output

MISO Multiple Input-Single Output

SISO Single Input-Single Output

SP Smith predictor

QP Quadratic programming

2DOF Two Degrees of Freedom

1 INTRODUÇÃO

Companhias de petróleo, gás natural e biocombustíveis trabalham sob um sistema de integração tecnológica e administrativa que envolve todas as atividades logísticas relacionadas a um bom planejamento da sua cadeia de suprimentos. Essas indústrias ocupam um espaço de significativa importância na economia global, sobretudo na economia brasileira. Trata-se de um setor de grande empregabilidade, responsável pelo surgimento de diversas tecnologias que atendem as mais variadas áreas de pesquisa. Para cumprir as expectativas de um mercado que está em ampla disputa, estratégias para armazenar e transportar produtos assumem um papel importante no cenário mundial e não podem ser ignoradas pelas empresas, qualquer que seja seu porte. O Brasil, como um importante fornecedor dos produtos, visa expandir essa liderança aproveitando sua evolução e grande processo de transformação, fazendo necessários investimentos crescentes em pesquisas brasileiras, tendo em vista a alta competitividade gerada pelo interesse de concorrentes estrangeiros no setor (CNI; DIRET; IBP, 2012).

Neste capítulo, são apresentados vários dos cenários que enfrentam a indústria do petróleo, gás e biocombustíveis brasileiros, além de conceitos e conhecimentos gerais à respeito das cadeias de suprimentos, possibilitando sustentar a proposta geral deste trabalho.


1.1 GESTÃO DE CADEIAS DE SUPRIMENTO

Os primeiros sistemas de armazenagem surgiram com a necessidade da humanidade garantir a sobrevivência em épocas de escassez. Em um primeiro momento, o objetivo era simplesmente estocar e consumir. Depois, além da questão da armazenagem propriamente dita, outros aspectos como perdas no sistema (devido à deterioração ou roubo) e garantia de abastecimento foram adicionados ao problema. Deste modo, os primeiros passos para o gerenciamento de estoques estavam sendo dados. Com o crescimento populacional das cidades e o desenvolvimento da manufatura após o advento da revolução industrial, sistemas de estoques cada vez maiores se tornaram necessários para garantir o abastecimento e sua gestão tomou um impulso de grandes proporções (PACHECO, 2004).

Quando uma companhia entrega um produto a um cliente, finaliza um processo que começou quando se teve conhecimento que o cliente queria adquiri-lo, ou no mínimo teve a expectativa de adquiri-lo. Este processo trans-

forma a informação que dá o cliente (*demanda*) em produtos para ele mesmo (*produtos entregues*). Uma cadeia de suprimentos (CS) é caracterizada por ter fluxos de materiais e fluxos de informação, como ilustrado na figura 1.1, a direção do fluxo de materiais de um fornecedor até seu cliente é considerado o fluxo que vai para frente da CS (*forward ou downstream*) por outro lado os fluxos de informação dos pedidos entre clientes e fornecedores, viajam para trás na CS (*backward ou upstream*). CS podem apresentar diferentes estruturas e sua complexidade pode variar conforme o tipo de produto final, tempo de produção, tempos de transporte e dependem também das variáveis envolvidas no processo de transformação das matérias primas. Da mesma forma, outro fator característico é o nível de incertezas sob o qual opera a CS. Para alguns mercados é mais fácil conhecer ou estimar a demanda e seu comportamento no tempo, assim como manter preços e custos mais estáveis (BENET; SUBIAS; GRIÑO, 2006).

Figura 1.1 – Diagrama simples da Cadeia de Suprimentos




Fonte: (PIN-HO; SHAN-HILL; JANG, 2004)

No caso de redes de CS que operam em países produtores de petróleo, segundo Eichmann (2000), a gestão das mesmas tem sido um dos mais difíceis desafios encontrados por pesquisadores da área no mundo. Cadeias de suprimento em petróleo e gás, envolvem uma série de subsistemas (ver figura 1.2), que interagem entre si nos processos de exploração, de transferência de petróleo para os terminais, de armazenagem em tanques e de transferência às refinarias para finalmente iniciar o processo de refino e produção dos derivados do petróleo (NEIRO; PINTO, 2004), enfrentando-se com condições de mercado incertas, mudanças econômicas que afetam diretamente as capacidades de processamento, de exportação, satisfação de demandas no mercado local e equilíbrio dos preços (AL-OTHAM et al., 2007). O principal obstáculo na otimização das unidades de produção está na busca da economia global do sistema. Normalmente, os objetivos das unidades individuais são conflitantes e muitas vezes inviáveis globalmente. O alvo principal no gerenciamento das cadeias de suprimento de petróleo e gás consiste em buscar uma integração entre os objetivos econômicos de produção e as condições de operação dos processos (NEIRO; PINTO, 2004). Contudo, procura-se uma abordagem mais eficiente

para integrar as limitações atuais e futuras na síntese do planejamento de produção, levando os objetivos de produção de curto prazo em condições de funcionamento para as unidades de processamento, fornecendo uma ferramenta de análise para o efeito de distúrbios econômicos no desempenho do sistema de produção dentro de horizontes e fornecendo mecanismos para levar em conta, tanto incertezas comerciais, como tecnológicas (limitações físicas) (AL-OTHAM et al., 2007).

Figura 1.2 – Cadeia de Suprimentos de Petróleo e Gás Natural



Fonte: (NEIRO; PINTO, 2004)

1.2 MOTIVAÇÃO

O petróleo não é um recurso natural renovável, é um recurso cada vez mais escasso e, assim, tende a ser cada vez mais valorizado. A exploração e produção do petróleo tem sido um dos focos de maior relevância na área de energia, visto que o Brasil almeja cada vez mais aumentar sua capacidade produtiva visando sustentabilidade. No quadro econômico, não são apenas produtos petrolíferos que competem contra outros produtos petrolíferos, senão também cadeias de suprimento que concorrem com outras cadeias de suprimento. Isso porque, ao eliminarem-se ineficiências dessas cadeias, podem-se economizar recursos, o que torna o produto final mais competitivo e rentável (SIMCHI-LEVI; KAMINSKY; SIMCHI-LEVI, 2004). Uma CS eficiente traz grandes

benefícios para a sociedade, uma vez que evita desperdícios e reduz impactos ambientais causados pela produção excessiva (SCHWARTZ; RIVERA, 2010).

Para as indústrias em geral, torna-se cada vez mais difícil concorrer em escala global sem fortes estratégias de gerenciamento de estoque. Mudanças nos padrões de consumo levaram empresas a mostrar um interesse crescente na gestão eficiente de seus sistemas logísticos. Novas normas para gestão dos resíduos geram um foco renovado de qualidade, acrescentando obstáculos para alcançar certificações internacionais e adoção de paradigmas de alta qualidade (SUBRAMANIAM et al., 2012). Nesse contexto, políticas de desenvolvimento que vêm sendo adotadas no setor petrolífero brasileiro, iniciadas há décadas, buscam, através da abertura do mercado, o aumento dos investimentos estrangeiros.

De acordo com a OPEC, o Brasil pode se tornar a nação com o maior aumento de reservas de Petróleo até 2020, passando da 14^a para a 8^a colocação no ranking mundial de reservas de petróleo (OPEC, 2013). Contudo, a maximização da produção de petróleo e derivados fortalece ainda mais a necessidade de se ter um gerenciamento dessa cadeia logística, de forma integrada e otimizada. Um melhor conhecimento dos pontos de ineficiência dessa cadeia produtiva permitirá a execução de um melhor planejamento integrado, com a programação e o controle das atividades. Portanto, as decisões de produção precisam ser rápidas e robustas frente às incertezas do mercado, porém otimizadas para atingir objetivos chave na CS. Para tal, um dos meios de se atingir o objetivo de aumento de produção consiste na utilização adequada dos recursos e otimização logística, de forma a aumentar a produtividade. Desse modo, sabe-se que a CS do petróleo que opera no país apresenta uma série de oportunidades de melhoria que certamente trarão benefícios muito relevantes. É nesse contexto que se inserem neste projeto, estudos de otimização e aplicação de teorias de controle preditivo, como ferramentas na gestão de cadeias de suprimento.

1.2.1 Setor Petrolífero no Brasil

A lei do petróleo (9.478 / 97) decretou a exploração de hidrocarbonetos feita sob o modelo de concessão, criou o conselho nacional de política energética (CNPE) e a agência nacional do petróleo (ANP), cujas principais funções são regulação, contratação e fiscalização das atividades inerentes à indústria do petróleo, bem como das atividades de distribuição e venda dos derivados de petróleo e álcool. O fim do monopólio estabelecido pela lei, trouxe uma série de avanços no sentido de estimular a concorrência e buscar sempre uma melhor produtividade dos campos maduros, seja ou, na uti-

lização e aproveitamento da infra-estrutura existente. Desse modo, apesar das dificuldades momentâneas presenciadas no fim do ano passado e no início deste ano, o país vem criando condições para uma expansão do setor, obrigando empresas envolvidas nestas atividades procurar condições ideais e muitas vezes ótimas de todos os processos da cadeia produtiva (TERUMICHI, 2007).

A indústria brasileira de petróleo e gás está passando por um período de grande transformação. O setor emprega em média 500 mil profissionais, número orientado ao crescimento para 2 milhões em 2020 (PWC, 2014). Estimulada pelos altos preços que tinham os petróleos no mercado internacional, investimentos da PETROBRAS na prospecção de reservas não-convencionais em águas profundas gerou uma nova era para a atividade petrolífera brasileira, em termos de reservas e produção. Com uma infraestrutura robusta de atividades de exploração e produção, o país é líder na produção mundial de hidrocarbonetos em águas profundas e ultraprofundas. Expandiu consideravelmente as oportunidades de crescimento na descoberta de extensas reservas de óleo e gás presentes no pré-sal do litoral a partir de 2006 (PETROBRAS, 2014). É importante destacar que o Brasil tem o recorde mundial de exploração de águas profundas em petróleo, cujo *know-how* adquirido permite à PETROBRAS continuar investindo nesse segmento de exploração (TERUMICHI, 2007). A exploração do pré-sal cria grandes oportunidades, mas, acrescenta desafios importantes para fornecedores da indústria brasileira de petróleo e gás (PETROBRAS, 2014); desafios de crescer com processos eficientes, melhores práticas de gestão, controles apropriados e equilibrados, custódios controlados. Além de melhores práticas de gestão, é necessário desenvolvimento tecnológico com o objetivo de melhorar a competitividade da cadeia de suprimentos brasileira e apoiar exigências de conteúdo local.

O petróleo produzido no país é pesado e exige um poder de refino maior. Refinarias brasileiras não têm capacidade de refinar todo o petróleo consumido internamente. Porém, o Brasil exporta petróleo cru e importa derivados, principalmente gasolina. No que se refere ao gás, o consumo brasileiro supera a produção. Para solucionar esse déficit, o país importa gás da Bolívia. Contudo, o Brasil implantou uma política local para fomentar o desenvolvimento da cadeia de suprimentos nacional, com o objetivo de torná-la forte e sustentável. Assim, a renovação da CS contribuirá para o aumento do peso da indústria de petróleo e gás no PIB brasileiro dos atuais 12%, para 20% em 2020, segundo previsões da PWC (2014).

Em prol do apoio ao desenvolvimento da indústria local, o governo brasileiro, por meio do BNDES (Banco Nacional de Desenvolvimento Econômico e Social), e a PETROBRAS oferecem várias fontes de financiamento como são: Plano Brasil Maior, Progredir e o Plano de Negócios da PETRO-

BRAS. Assim, segundo o relatório da PWC (PWC, 2014), o programa brasileiro de exploração de petróleo representa um dos projetos mais caros do mundo em andamento, ao lado do trem de alta velocidade chinês e da construção de uma infraestrutura física e esportiva para uma copa do mundo de futebol (FIFA) no Catar (PWC, 2014).

1.2.2 Etanol a partir de Biomassa

A utilização da biomassa é uma ferramenta útil para adotar esquemas sustentáveis de plantas industriais e contribuir ainda mais para o uso de energia limpa. A produção de álcool e hidrocarbonetos a partir de biomassa tornou-se uma importante área de estudos de CS devido ao crescimento explosivo gerado pelos regulamentos ambientais e necessidades de energia renováveis (AN; WILHELM; SEARCY, 2011). O processamento de cana no Brasil é feito através de uma cadeia de produção muito integrada. Açúcar e etanol são produzidos em um processo combinado com um sistema de co-geração para suprir a demanda de energia necessária, trabalhando em um processo de produção autônomo (PERAN et al., 2011).

A indústria sucroalcooleira figura entre as mais tradicionais e antigas no Brasil. Entretanto foi em 1975 que a indústria ganhou um novo impulso, após a primeira crise do petróleo, quando foi instituído o Proálcool. Esse programa governamental tinha como meta principal, a produção de álcool hidratado para ser utilizado como combustível substituto da gasolina. Destarte, após décadas, o fato de ter uma matriz energética diversificada diminuiu o risco do país depender de alimentação externa para cumprir com a demanda do mercado (AMERICANO, 2013). Aliás tem gerado um *commodity* nacional e internacional com o etanol, reconhecido como uma alternativa concreta para a substituição de combustíveis fósseis destacando o Brasil como um país importante e em desenvolvimento que apoia políticas internacionais de meio ambiente como o protocolo de Kyoto, assinado em 1998. Dessa maneira, as indústrias brasileiras do açúcar e álcool vêm desempenhando um papel notável no que se refere à preservação do meio ambiente (AMERICANO, 2013).

No Brasil, a partir de 2009 a subsidiária da Petrobras (Petrobras Bio-combustível) começou trabalhar fortemente no setor, apresentando novas tecnologias para produção de etanol de segunda geração. Assim, a adoção do etanol como combustível nacional, defendido por políticas governamentais, tem se mostrado como alternativa concreta na produção de energia sem poluir, ajudando na economia do país, garantindo, além do abastecimento, melhor qualidade de vida, não somente como forma de reduzir a emissão

de gases poluentes, mas também de transformação social (GAGLIARDO; COR-SANO, 2011).

1.2.3 Gestão de cadeias de suprimento mediante MPC

O uso de técnicas de controle para o problema de eficiência das CS tem crescido fortemente desde a segunda metade do século XX. Trabalhos nessa área incluem a modelagem de processos de CS usando analogia de fluidos através de comparações com sistemas de controle de nível em tanques acoplados (SCHWARTZ; RIVERA, 2010), bem como o controle desse sistema através de técnicas em malha fechada (NANDOLA; RIVERA, 2013).

De acordo com Al-Otham et, al. (2007), o gestão dos sistemas de CS visa minimizar custos de produção, minimizar excessos de armazenamento e minimizar as despesas de transporte, assim como satisfazer as demandas dos clientes, mantendo uma participação ativa no mercado. É por isso, que as técnicas de controle preditivo encaixam perfeitamente como uma possível solução nos problemas de gestão de cadeias de suprimento. O MPC oferece flexibilidade em termos de troca de informação, topologias de rede e manipulação de restrições. Além disso, o MPC trabalha sob otimização de objetivos. Objetivos que podem ser projetados para considerar informações econômicas, como também levar em conta objetivos mais comuns da teoria de controle, como rastreamento de referências, e especificações dinâmicas de suas variáveis (CAMACHO; BORDONS, 2004). Dessa maneira, o problema pode ser escalado para manter o nível de estoque dentro de certos valores pré-determinados e, ao mesmo tempo, proporcionar um funcionamento economicamente ideal no processo de fabricação; em outras palavras, evitar mudanças rápidas no ritmo de produção e, ao mesmo tempo, evitar quantidades indesejáveis de produtos em estoque.

Grande parte das pesquisas focadas no controle de CS buscam melhorar o *bullwhip* - (*efeito chicote*), fenômeno que decorre, na maioria dos casos, dos atrasos presentes na dinâmica de cadeias de suprimento (PIN-HO; SHAN-HILL; JANG, 2004). Esse fenômeno normalmente observado em CS não administradas, refere-se à ocorrência de picos de estoque de amplitude relativamente grande quanto comparados à real variação da demanda.

Processos com essa característica de atraso, muitas vezes elevado, são difíceis de controlar usando controladores preditivos padrão (NORMEY-RICO; CAMACHO, 2007), uma vez que a robustez desses sistemas de controle tende a ser baixa frente a incertezas na estimação do modelo e na estimação de perturbações (demanda, para este caso). Ainda, devido à quantidade de processos envolvidos, o processo como um todo tem um grande número de variáveis

e dinâmicas complexas, o que gera dificuldades para o desenvolvimento de algoritmos de controle eficientes. Nessa situação de complexidade no modelo e elevado atraso de tempo, propõe-se neste trabalho o uso de técnicas de controle preditivo baseado em modelo, visando aproveitar sua estrutura de compensação de atrasos de tempo explícita, buscando aliar as vantagens do controle preditivo com a robustez necessária para aplicação prática. Como será mostrado, esses controladores podem ser configurados e ajustados para atingir bom desempenho e robustez em CS com atrasos de tempo incerto.

A problemática de gestão de cadeias de suprimento é uma área de aplicação emergente que foge das aplicações tradicionais da engenharia de controle de sistemas e, portanto, os estudos sobre técnicas de controle aplicadas a esse problema ainda não estão concluídos. Análises mais detalhadas da influência do atraso na robustez dos controladores ainda precisam ser mais bem elaboradas (NANDOLA; RIVERA, 2013). Assim, neste trabalho se estudará a aplicação de algoritmos de compensação de atraso e técnicas de otimização baseadas em funções objetivo sob MPC para o controle de CS.

1.3 OBJETIVOS

O objetivo geral deste trabalho é focado no estudo da cadeia de suprimentos de *dowstream* na indústria de petróleo, gás natural e biocombustíveis implementando controle preditivo para manter os estoques. Compreendendo assim, o sistema de processamento do petróleo nas refinarias e armazenagem dos derivados para sua posterior comercialização atendendo ao mercado consumidor. No caso dos biocombustíveis, o sistema é considerado a partir do processo de transformação da cana-de-açúcar em álcool e produtos derivados importantes para sua cadeia produtiva. Em particular propõe-se o estudo de controladores com compensação explícita do atraso em cadeias de suprimento que experimentem efeitos de *bullwhip*, visando corrigir-o e atingir bom desempenho e boa robustez. Mais especificamente busca-se examinar a estrutura das cadeias de suprimento, evidenciando o problema do atraso de transporte no fluxo de materiais e informação, estudando boas soluções que amortecem adequadamente oscilações provenientes da operação sujeita a incertezas típicas de demanda e que mantenham os níveis dos estoques para o comportamento requerido pelo mercado.

1.4 ESTRUTURA DA DISSERTAÇÃO

Este documento contém 6 capítulos.

No *Capítulo 2* discute-se a aplicação da teoria de controle em cadeias de suprimentos, explica-se a problemática comum dos sistemas e as especificações típicas para o controle. São abordadas as metodologias mais comuns para modelagem dos sistemas de CS. Apresenta-se também uma revisão da literatura com vários dos estudos sobre o controle de CS e são abordadas vantagens de usar técnicas de controle preditivo para obter boas soluções em CS.

No *Capítulo 3* descrevem-se os conceitos básicos de controle preditivo baseado em modelo, apresentam-se a metodologia do GPC e suas características mais importantes; apresenta-se como a formulação é facilmente extensível para o caso multivariável. Ainda no *Capítulo 3* são incluídas questões chave para o uso da estrutura de compensação de atraso de tempo na predição, ideias que serão utilizadas ao longo do trabalho como forma de melhorar o desempenho dos algoritmos GPC para sistemas com atrasos e divergências significativas na modelagem.

No *Capítulo 4* são explicadas estratégias de coordenação na implementação do controle em sistemas de CS aplicado a um exemplo geral para controle de estoques. É revisada a modelagem do sistema e a aplicação do algoritmo de controle como solução do problema de estoques. Além disso, é avaliado o comportamento do sistema operando sob incertezas na previsão da demanda.

No *Capítulo 5* mostram-se e discutem-se os resultados obtidos em sistemas de CS simulados em ambientes próprios para estudos na indústria de petróleo, gás natural e na indústria de biocombustíveis, avaliando características de desempenho dinâmica e econômica dos sistemas.

No *Capítulo 6* apresentam-se tanto as conclusões deste trabalho, como sugestões para trabalhos futuros e comentários finais.

2 TEORIA DE CONTROLE EM CADEIAS DE SUPRIMENTO

Na sequência serão apresentados os princípios de funcionamento e os modelos matemáticos adequados para descrever os sistemas de armazenamento em cadeias de suprimento. Outro assunto discutido neste capítulo é a característica dos atrasos de tempo tipicamente presentes nos sistemas de CS. Finalmente, serão apresentados os objetivos e as vantagens ao se aplicarem teorias de controle preditivo junto com uma rápida revisão da literatura que abrange estudos em aplicação da teoria de controle para gestão de estoques.


2.1 PROBLEMÁTICA

Uma cadeia de suprimento é um processo de fabricação integrado, em que as matérias-primas são convertidas em produtos finais entregues aos clientes. No seu mais alto nível, grosso modo, uma CS é composta por dois processos integrados básicos: (1) o planejamento de produção e controle de estoque, e (2) a distribuição e processo de logística. Esses processos proporcionam um quadro básico para a conversão e a transformação de matérias-primas em produtos finais (BEAMON, 1998). O processo produtivo e planejamento e controle de estoque abrange os sub-processos de fabricação, armazenamento, e sua interface. Descreve a concepção e gestão das políticas e procedimentos de armazenamento de matérias-primas, estoques de produto em processo (produto semi-acabado), e, geralmente, produtos finais. Distribuição e processo logístico, determinam como os produtos são recuperados e transportados a partir do armazém para os varejistas ou clientes finais. Esses produtos podem ser transportados para os varejistas diretamente, ou podem ser primeiro levados para centros de distribuição, para finalmente serem entregues aos varejistas. Esse processo inclui a gestão de recuperação de estoque, transporte e entrega do produto final (BEAMON, 1998). Dessa maneira, dificulta-se a integração dos processos logísticos. As complexidades envolvidas em cada uma das atividades do processo intervêm em várias dependências de uma ou várias empresas diferentes (*cada uma com critérios próprios de otimização de sua própria gestão*), portanto a atividade de cada uma pode ser afetada pelas decisões das outras (BENET; SUBIAS; GRIÑO, 2006).

Os níveis de estoque da CS dependem da quantidade produzida na fábrica e da demanda dos clientes. O problema de controle é manter o nível de estoque dentro valores pré-determinados, proporcionando um funcionamento economicamente ideal no processo de fabricação; em outras palavras, evitar mudanças rápidas e quantidades indesejáveis de produto no estoque. Os

atrasos de tempo têm uma influência importante e são causados pelo tempo necessário para que os pedidos de produtos sejam processados e emitidos, como esquematizado na figura 2.1. Os atrasos podem descrever horas, dias ou semanas, tudo depende do sistema produtivo modelado.

Figura 2.1 – Tempos de produção e transporte na CS



Fonte:(BERNHARD; MARIOS, 2000)

O problema de fato com o atraso são as limitações físicas, que não permitem que produtos sejam produzidos ou entregues até o decorrer dos tempos de atraso após a recepção dos pedidos. São tempos de espera presentes na dinâmica do modelo. Como ilustrado na figura 2.1, o atraso pode estar presente em todas as etapas da CS. As demoras se dão: (1) no fluxo de materiais, devido aos tempos do processo produtivo, como fabricação, testes de qualidade, e transportes dos lotes entre os elos envolvidos; (2) no fluxo de informação, devido aos tempos de recepção e encaminhamento dos pedidos, como envio de ordens de compra e confirmação de pagamentos (MIN; ZHOU, 2002). O atraso de tempo faz com que o efeito da demanda (perturbações na CS) não seja considerado até que um tempo de atraso tenha decorrido. Em termos de controle, o atraso de tempo faz que o efeito da ação de controle leve algum tempo para ser observada na variável controlada e que a ação de con-

trole que é aplicada (calculada com base num erro atual) tente corrigir uma situação originada em algum instante de tempo anterior, o que pode causar instabilidade (NORMEY-RICO; CAMACHO, 2007).

De acordo com Sarimveis et, al. (2007), para projetar sistemas de gestão em CS a engenharia de controle está excepcionalmente qualificada para fazer contribuições de base ampla neste problema. O comportamento dinâmico típico de cadeia de suprimentos justifica o interesse por técnicas de MPC (NORMEY-RICO; CAMACHO, 2007). O MPC oferece alta flexibilidade em termos de partilha de informações, topologia da rede, e manipulação de restrições (SUBRAMANIAM et al., 2012). O apelo do MPC para gestão de estoques na dinâmica das cadeias de suprimento pode ser resumida como: (1) um otimizador, no qual, pode-se minimizar ou maximizar uma função objetivo que representa uma medida adequada para o desempenho da cadeia de suprimentos; (2) um controlador, o qual, pode ser ajustado para alcançar estabilidade, robustez e bom desempenho na presença de incompatibilidades ou erros na modelagem, falhas e perturbações que afetam o sistema (NANDOLA; RIVERA, 2013). Também, a informação da previsão de demanda (perturbações) no horizonte pode ser empregada no cálculo para antecipar o comportamento futuro do sistema, o que desempenha um papel significativo no uso de MPC para aplicações de cadeias de suprimento (SCHWARTZ; RIVERA, 2010). Com respeito aos sistemas de gestão de CS com característica de atrasos de tempo significativo, propõe-se neste trabalho usufruir da estrutura de compensação de atraso de tempo explícita no preditor. O principal objetivo do preditor é compensar o efeito do atraso de tempo no sistema. Ademais, com um ajuste adequado é garantido o bom desempenho do sistema na presença de ruído ou de perturbações e a robustez do sistema, quando incertezas de modelagem são consideradas (NORMEY-RICO; CAMACHO, 2007).

2.2 MODELOS DE CADEIA DE SUPRIMENTO

Pesquisadores e profissionais têm investigado principalmente os vários processos de fabricação dentro de cadeias de fornecimento individualmente. Uma crescente atenção sobre o desempenho, projeto, e análise da CS como um todo surge a partir da necessidade de obter um melhor desempenho na administração da cadeia de suprimentos. Esta atenção é em grande parte resultado do aumento dos custos de produção, ciclos de vida de produto mais curtos, bem como a globalização das economias de mercado (BEAMON, 1998).

Considerando um espectro global do conceito de CS, existem esquemas de classificação para categorizar os modelos da cadeia de suprimentos. A literatura apresenta várias categorias, que dependem da natureza das variáveis

e do objetivo de estudo. O trabalho de (MIN; ZHOU, 2002) resume as seguintes categorias:

- *modelos determinísticos*, em que as variáveis são conhecidas e especificadas;
- *modelos estocásticos*, em que no mínimo uma das variáveis é desconhecida, ou seja, há parâmetros incertos e aleatórios;
- *modelos híbridos*, os quais têm elementos de ambos os tipos de modelos: determinísticos e estocásticos. Estes incluem modelos de estoque teóricos e de simulação que são capazes de lidar com as incertezas dos parâmetros do modelo;
- *modelos ET-driven*, gerados a partir de desenvolvimentos em inovações e subsequente reengenharia do processo de negócio. Modelos de *tecnologias da informação* - TI, visam integrar e coordenar as diversas fases de planejamento da cadeia de suprimentos numa base em tempo real, utilizando software de aplicação.


Este trabalho está focado para utilizar modelos híbridos. Baseados em trabalhos apresentados em (FU; AGHEZZAF; KEYSER, 2014) e (NANDOLA; RIVERA, 2013), empregam-se modelos determinísticos discretos que representam as dinâmicas das cadeia de suprimentos em conjunto com modelos estocásticos no caso de demandas que presumem-se seguir uma distribuição de probabilidade.

A fim de aprofundar na área de modelagem para a análise de sistemas de CS, o leitor é remetido para os trabalhos de (BEAMON, 1998) e (MIN; ZHOU, 2002), nos quais podem-se encontrar estudos mais detalhados.

2.2.1 Modelagem Matemática

O MPC utiliza um modelo matemático explícito para calcular corretamente as predições do comportamento do sistema no futuro. Desse modo, um bom modelo representa uma grande vantagem no uso do MPC como metodologia de controle do sistema de CS. A obtenção de um modelo matemático adequado que descreva com detalhe suficiente a dinâmica e aspectos de interesse no sistema de CS deve ser o mais simples possível, facilitando sua análise e simulação. Baseado no estudo feito por Valladares (2014), propõe-se um modelo discreto que representa um dos estágios de uma cadeia de suprimentos, figura 2.2. Nela, um fornecedor recebe matéria prima para produzir itens de um certo tipo. Uma vez prontos, eles são estocados no armazém. Esse, por sua vez, os transfere para a loja que os vende para os consumidores finais.

Figura 2.2 – CS simplificada de três estágios



Fonte:Elaborado pelo autor

Seguindo essas hipóteses, os comportamentos de cada um dos estágios podem ser descritos como:

- fornecedor: recebe pedidos do armazém e, seguindo regras de decisão internas, produz itens para supri-lo. O tempo entre disparar a ordem de produção e as quantidades de itens e sua disponibilização para entrega é chamado $\theta_{fornecedor}$ e, por simplicidade, não dependerá da quantidade de itens;
- armazém: recebe pedidos da loja e, seguindo regras de decisão internas, faz requerimento ao fornecedor. O tempo entre pedir as quantidades de itens ao fornecedor e tê-los prontos para envio é θ_{armazm} ;
- loja: recebe pedidos dos consumidores e, seguindo regras de decisão internas, faz solicitação ao armazém. O tempo entre pedir as quantidades de itens ao armazém e tê-los prontos para venda é θ_{loja} ;

Se for considerado também que não há restrições de pedidos mínimos ou máximos e que é possível fazê-los qualquer dia, os três estágios podem ser descritos nas equações (2.1) e (2.2), sendo equações que satisfazem as leis de conservação de acordo com pedidos (material) feitos e recebidos, da rede de CS ilustrada na figura 2.2:

$$I_i(k) = I_i(k-1) + O_i(k) - D_i(k), \quad (2.1)$$


$$O_i(k) = u_i(k - \theta). \quad (2.2)$$

sendo k uma unidade de tempo discreto, como horas, dias, semanas, $I_i(k)$ a quantidade de itens disponíveis em estoque, $O_i(k)$ a quantidade de itens recebidos ou cuja produção está finalizada, $d_i(k)$ a quantidade de itens

enviados ou vendidos e $u_i(k)$ a quantidade de itens pedidos, que age como as entradas, ou sinal de controle desse sistema. $d_i(k)$ é uma função de demanda que retrata a saída de itens, porém, representa as perturbações no sistema. Vale enfatizar que θ não depende de k , o atraso é constante. Sem essa consideração a complexidade do estudo aumentaria consideravelmente.

Na figura 2.3 mostra-se o diagrama de blocos do sistema de controle para o modelo em (2.1) e (2.2). Usando terminologia de controle, a planta estudada é um acumulador, submetido a um controle com atraso somado a distúrbios aleatórios na sua entrada (VALLADARES, 2014).

Figura 2.3 – Diagrama de blocos do modelo simplificado da rede de CS



Fonte: (VALLADARES, 2014)

De acordo com Simchi-Levi (2004), considera-se que o fornecedor nunca carece de matéria-prima ou tem amplas mercadorias em estoque para satisfazer os seus clientes (demandas). Portanto, com esta aproximação e aplicando transformada z de ambos os lados do modelo em (2.1), obtém-se (2.3).

$$y_i(k) = \frac{1}{1 - z^{-1}} z^{-\theta} (u_i(k) - d_i(k)) \quad (2.3)$$

Assim, o modelo de tempo discreto, para o nó i (i = fábrica, armazém, loja etc.) capta as características dinâmicas do fluxo de material e do fluxo de informação no sistema da cadeia de suprimento. Na equação (2.3) a variável $I_i(k)$ foi reemplazada por $y_i(k)$, comumente usada para definir a saída do sistema ou variáveis controladas. A maneira de tratar esses modelos de forma estendida, combinando a função de transferência de cada nó num sistema, será exemplificada no capítulo 4.

2.2.2 Especificações típicas para Controle

Para o controle de cadeia de suprimentos podem ser projetadas tantas malhas de controle quanto forem necessárias, dependendo da topologia de rede e dos objetivos desejados. A otimização da estruturação de rede envolve a centralização ou descentralização do sistema de gestão. Uma distribuição adequada da rede consolida o desempenho na CS. As decisões de controle são obtidas a partir da otimização de funções custo dadas, os problemas são especificados como funções de uma ou mais variáveis de decisão. Geralmente, os principais ambientes são redes de produção, desse modo, especificam-se todas as variáveis de decisão envolvidas e o problema é projetado (por exemplo, maximizando rendimentos / minimizando custos), (LI; MARLIN, 2009).

É comum caracterizar o problema de controle segundo os requerimentos definidos na programação da produção, assim, são definidos e especificados os parâmetros do sistema. Exemplos típicos são: especificação de capacidade (espaço disponível) para estocagem e manufatura, muitas vezes definidos como restrições do sistema. Com tal característica, o uso do MPC, apresenta vantagens devido à facilidade na manipulação das restrições, constituindo mais uma razão na escolha dessa metodologia para o controle do sistema de CS. Outros exemplos tais como: janelas de tempo, datas de entrega, tempo máximo de fabricação, número de horas de condução para motoristas (transporte de matérias primas e produtos terminados), etc, podem ser levados em conta na modelagem dos sistemas ou definidos nas especificações de controle.

As variáveis manipuladas são as quantidades necessárias (pedidos) de material. Aqui é definido o volume de produção. Esta variável inclui o volume ideal para aquisição de matéria-prima, produção de mercadorias e volumes de transporte de materiais em cada nó da cadeia de suprimentos. As variáveis controladas são os níveis dos estoques (quantidades em estoque). Estas variáveis representam a quantidade ideal de cada material para ser armazenado em cada etapa da cadeia de suprimentos.

As perturbações atuantes no sistema são oriundas da evolução da demanda do mercado, e do padrão de produção. O mais prejudicial para o funcionamento do sistema de controle de CS, é o regime de variações severas na demanda. Desse modo, o objetivo é manter o estoque próximo da referência e rejeitar o distúrbio. Isto significa atender a demanda sem desviar dos valores próximos à referência desejada para o estoque.

2.3 CONTROLE DE CADEIAS DE SUPRIMENTO NA LITERATURA

Inicialmente, começou-se a utilizar a teoria de controle no estudo de CS a partir da aplicação de servomecanismos de tempo contínuo, manipulando a taxa de produção em um sistema simples que envolvia um único produto (HERBET, 1952). Posteriormente, estenderam-se essas ideias a modelos de tempo discreto para controle de estoques baseados nos conceitos da transformada z (VASSIAN, 1955). Na sequência, introduziu-se o modelo *Forrester*, que permitiu abordar problemas no âmbito de organização industrial. Seu amplo uso para ilustrar os problemas presentes nas CS facilitou e forneceu uma ferramenta poderosa para a utilização de técnicas de controle no gerenciamento de estoque (TOWILL D.AND NAIM; WIKNER, 1992). São muitas as contribuições na aplicação da teoria de controle clássica que se tem na literatura, as quais, basicamente visam atenuar as flutuações causadas pelas variações de demanda e ao mesmo tempo manter os níveis de estoque dentro de restrições. Métricas de controle padrão são usadas para quantificar o desempenho, avaliando características de performance dinâmica (SARIMVEIS et al., 2007). Também existem registros acadêmicos na aplicação de técnicas de controle *feedforward* usado para alcançar erro zero em estado estacionário dos estoques, assim como a implementação da metodologia *PID* no para reduzir níveis de estoque e custos de produção (SCHWARTZ; RIVERA, 2010). Conceitos de controle *Fuzzy* também provados para abordar problemas em gestão de estoques (WANG, 2009).

Para processos industriais o MPC tornou-se um sistema de controle padrão. Isto porque, o MPC lida eficientemente com restrições e não linearidades dos sistemas dinâmicos multivariáveis (CAMACHO; BORDONS, 2004). No ano de 1992, aplicou-se pela primeira vez a teoria de controle preditivo em um problema de gerenciamento de estoques, com foco em um problema local de fabricação. Nesse estudo, (KAPSIOTIS; TZAFESTAS, 1992), tentaram compensar os prazos de produção, incluindo na função custo do controlador um termo de penalidade nos desvios da trajetória de referência. Posteriormente, muitos trabalhos surgiram com aplicação da teoria de controle preditivo em gestão de CS. (PEREA; YDSTIE; GROSSMANN, 2003), empregam um esquema MPC para otimizar toda uma rede multi-produto, multi-nodular com uma demanda determinística. No trabalho são comparadas as abordagens de gestão centralizada e descentralizada, com aumentos de lucro de até 15% nas simulações em que empregaram a estrutura centralizada. Além disso, ressaltam as vantagens dos horizontes moveis para atualizar a variáveis de decisão sempre que aconteçam mudanças que afetam a CS. (BRAUM et al., 2002), têm apresentado trabalhos com MPC para gestão de CS desde o início do milênio, principalmente na área de manufatura de semicondutores. Suas

pesquisas abarcam várias metodologias para o controle de estoque. Em 2002 propuseram um esquema MPC linear para problemas nas CS de grande oferta na indústria de semicondutores. Através de experimentos, mostraram que o MPC pode lidar adequadamente com as incertezas resultantes por incompatibilidade de modelo e erros na previsão da demanda. Devido à complexidade da cadeia de suprimentos, trabalharam com um esquema descentralizado. Os objetivos para cada controlador MPC eram manter os níveis de estoque o mais próximo possível dos valores de referência, desde que satisfizessem as capacidades de produção e restrições de transporte. (WANG; RIVERA; KEMPF, 2003), aplicam uma abordagem centralizada para um modelo de CS simples de dois nós. Em seu trabalho usam a modelagem por analogia de fluidos e conseguem mostrar um bom desempenho do controlador MPC, satisfazendo a demanda frente a erros na modelagem e incrementos nos atrasos do sistema. Também é apresentado um exemplo mais realístico, para um sistema de quatro nós usando um só controlador MPC demonstrando robustez e níveis dos estoques razoáveis. (SCHWARTZ; RIVERA, 2010), resumem a descrição matemática de um modelo nominal por meio de analogia de fluidos para sistemas de armazenamento. Suas contribuições sugerem políticas de controle PID, IMC e MPC expondo a necessidade de aplicar ações feedback e feedforward, para gerar mais grau de liberdade para o controlador, permitindo abordar de forma independente vários conflitos presentes nas CS, como são os níveis críticos de estoque em presença de demanda incerta. (NANDOLA; RIVERA, 2013), apresentam uma formulação de controle híbrido encaixado perfeitamente nas estruturas CS que envolvem dinâmicas contínuas e decisões lógicas (eventos discretos). Obtém um modelo de controle MPC com três graus de liberdade visando um ajuste independente para seguimento de referência, rejeição de perturbações não mensuráveis e rejeição antecipada das perturbações conhecidas ou mensuráveis. Encoraja-se o leitor a ler os trabalhos de (SARIMVEIS et al., 2007) e (SUBRAMANIAM et al., 2012) para uma revisão mais detalhada da aplicação de técnicas de engenharia de controle para os problemas de CS.

Agora bem, para casos mais específico nas indústrias de petróleo, gás natural e biocombustíveis a literatura exhibe vários estudos em otimização para o modelagem e planejamento em gestão da CS usando programação linear e controle ótimo. Alguns trabalhos como o de (NEIRO; PINTO, 2004), apresentam um quadro geral para a modelagem das cadeias de suprimento de petróleo. Propuseram também um modelo em grande escala do fornecimento de petróleo numa refinaria localizada estrategicamente num mercado de consumo importante no Brasil. A topologia foi criada a partir de estruturas gerais básicas: modelo de unidade de processamento, modelo de unidade de armazenamento (tanque) e modelo das unidades de transporte (oleoduto). O problema de otimização é então a maximização do lucro obtido pelas ven-

das menos os custos relacionados com a matéria prima, operações, estoque e transporte de produtos. Por sua parte, (AL-OTHAM et al., 2007), indicam um padrão realista para otimização duma cadeia de suprimento numa empresa petroquímica que envolve todas as atividades relacionadas à produção, processamento e distribuição num país produtor de petróleo que opera sob condições econômicas incertas. São avaliados modelos determinísticos e estocásticos. O modelo de programação estocástica proposto mostrou-se bastante eficaz na determinação de planos de produção óptimos que minimizem os riscos que normalmente são encontrados devido às flutuações nas condições do mercado. Concluem assinalando que planejamento num ambiente econômico incerto é arriscado. Porém, é importante que a organização de petróleo desenvolva e implemente planos de produção flexíveis visando ter uma carteira diversificada. No mesmo campo, biocombustíveis compõem uma área importante de estudos em gestão da sua CS devido ao crescimento e ampla aceitação do produto como uma ótima solução as necessidades de abastecimento e sustentáveis. O importante estudo feito por (AN; WILHELM; SEARCY, 2011), citam em seu trabalho numerosas contribuições que foram publicadas na última década sobre gestão da CS em organizações produtoras de biocombustíveis e indústrias de combustíveis à base de petróleo. Além disso, apresentam literatura sobre modelos de cadeia de suprimento relevantes e genéricos para o tratamento destes sistemas, analisando como realizar a integração dos níveis de decisão que geram impacto na indústria.

2.4 COMENTÁRIOS FINAIS DO CAPÍTULO

Neste capítulo foram apresentados os problemas fundamentais em sistemas de gestão de CS em conjunto com uma exposição de soluções utilizando técnicas de controle preditivo. Foram explicados os princípios para modelagem dinâmica das cadeias de suprimento, e objetivos alvo do controle. Também se analisaram os modelos utilizados para a estabelecer os cenários de simulação nos resultados mostrados nos capítulos 4 e 5. No próximo capítulo será realizada uma revisão bibliográfica sobre MPC e técnicas utilizadas para amortecimento de perturbações e compensação do atraso de tempo.

3 CONTROLE PREDITIVO (MPC)

No capítulo 2 foram discutidos os princípios de modelagem e objetivos de controle dos sistemas de CS. A seguir serão apresentadas técnicas de controle preditivo que serão aplicadas a estes processos. Primeiramente nas seções 3.1, 3.2 e 3.3 será realizada uma descrição breve sobre MPC e na sequência na seção 3.4 é apresentada a fundamentação teórica do controlador GPC. Posteriormente na mesma seção serão apresentadas técnicas de controle GPC com restrições e apresenta-se a metodologia DTC-GPC, útil em processos sujeitos à ação de perturbações e erros de modelagem comuns em sistemas de CS, para finalizar descreve-se também a extensão para o caso multivariável na seção 3.5.

3.1 CONCEITOS BÁSICOS DE CONTROLE PREDITIVO BASEADO EM MODELO (MPC)

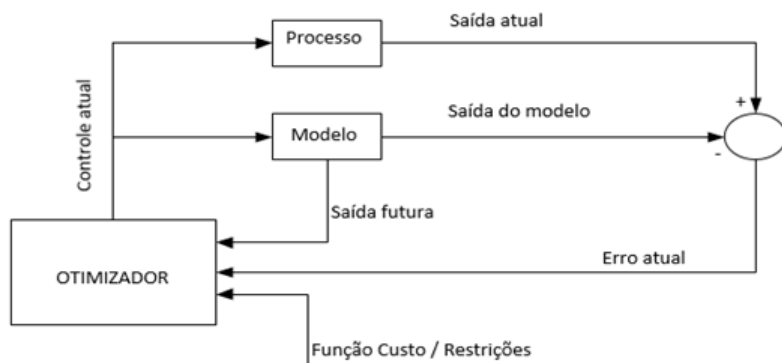
O MPC é um conjunto de metodologias desenhadas para obter controladores eficientes e regidos segundo a estrutura de otimização padrão. A estratégia de controle é baseada na predição do comportamento futuro da saída de um processo. Para realizar a predição, o MPC usa um modelo explícito do sistema para prognosticar o comportamento das variáveis controladas nos futuros instantes de tempo e para um horizonte definido. As sequências de controle são obtidas por meio da minimização ou maximização de uma função custo dada, cujo objetivo é atingir o valor do controle ótimo segundo as restrições físicas ou econômicas do processo. O MPC trabalha sob o conceito de janela móvel, ou seja, apesar da minimização da função objetivo resultar em um vetor de controles que devem ser aplicados no tempo, na amostra seguinte ao cálculo apenas a primeira ação de controle será aplicada e todas as ações de controle serão recalculadas de acordo com as novas informações obtidas do sistema real.

3.2 ESTRUTURA BÁSICA DOS CONTROLADORES PREDITIVOS

O MPC usa uma estrutura como a mostrada na figura 3.1. A predição ótima depende das ações de controle futuras, dos valores das saídas e entradas passadas, do modelo do processo, da função custo e das restrições quando estas são necessárias. Portanto, o modelo escolhido, deverá represen-

tar ao máximo a dinâmica do processo, atingindo previsões mais próximas da realidade.

Figura 3.1 – Estrutura básica do MPC



Fonte: Elaborado pelo autor

A seguir serão apresentados os elementos mais comuns nas estratégias do controle MPC: o uso explícito do modelo para previsão, a função custo ou objetivo empregada para otimização, e o cálculo da lei de controle.

3.2.1 Modelo de previsão

O modelo de previsão é o modelo resultante da caracterização do sistema. A estratégia MPC obriga buscar um modelo de previsão suficientemente rico que permita obter boas previsões do comportamento do processo o mais perto possível da realidade, o modelo deve ser fácil de usar, analisar e compreender. O modelo de previsão é composto pelo modelo do processo e pelo modelo das perturbações e é o elemento mais importante em um algoritmo de controle preditivo. Como o MPC baseia todo seu cálculo da lei de controle no modelo de previsão, todas as vantagens do uso de controle preditivo podem ser perdidas caso o modelo que está sendo usado não represente adequadamente a dinâmica do processo.

A grande maioria dos controladores preditivos baseados em modelo usados na indústria, empregam modelos de previsão lineares. Nestes casos para representar o processo no MPC é frequente o uso da resposta ao impulso ou a resposta ao degrau, além de representação por meio de funções de transferência, e de modelos a partir de variáveis de estado.

- *modelo de resposta ao impulso*: representação válida só para sistemas estáveis, pois submete-se o modelo do processo a uma excitação tipo impulsiva. O algoritmo MAC utiliza este modelo para realizar as previsões, (RICHALET et al., 1978).
- *modelo de resposta ao degrau*: como na representação anterior, a representação do processo usando a resposta ao degrau é usada para dinâmicas estáveis, (existindo uma extensão para o uso em sistemas de tipo integrador) (NORMEY-RICO; CAMACHO, 2007). Uma vantagem deste método é que permite uma fácil identificação e para tal não é necessário muita informação prévia do processo. O algoritmo DMC emprega este modelo para obter suas previsões, (GARCIA; MORSHEDI, 1985).
- *modelo de função de transferência*: a relação entrada/saída está dada por uma função de transferência discreta e é válida para sistemas que apresentem dinâmicas estáveis e instáveis. Este modelo exige conhecimentos e informação específica quando deseja-se identificar os parâmetros da função de transferência. Algoritmos como o GPC, EPSAC e EHAC usam este modelo para realizar a previsão, (CLARKE; MOHTADI; TUFFS, 1987),(GARCIA; PRETT; MORARI, 1989).
- *modelo no espaço de estados*: tem como vantagem que é possível representar sistemas multivariáveis e sistemas não lineares de forma simples. A literatura dispõe deste tipo de modelos, muito usados na representação de processos químicos, petroquímicos, aeronáuticos, eléctricos (GARCIA; PRETT; MORARI, 1989).

3.2.2 Função custo

Em geral propõe-se a função custo visando obter uma lei de controle que permita à saída futura seguir uma trajetória de referência para um horizonte desejado e ao mesmo tempo penalize o esforço do controle. Para casos mais específicos a função custo pode mudar, incluindo mais variáveis a serem otimizadas. A função custo considerada aqui se mostra na equação (3.1).

$$J(k) = \alpha \sum_{j=N_1}^{N_2} [y_p(k+j|k) - w(k+j|k)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(k+j-1|k)]^2 \quad (3.1)$$

Em (3.1), $\Delta u(k) = u(k) - u(k-1)$, são os incrementos de controle, $y_p(k+j|k)$ é o vetor com as previsões ótimas j passos em frente da saída do sistema com a informação fornecida até o instante k . $w(k+j|k)$ é o vetor

de referência. α e λ são as ponderações do erro de predição e dos esforços de controle, respectivamente. A função é minimizada para os horizontes de predição, $N = N_1 - N_2$, e de controle, N_u , definidos. Os parâmetros anteriores são usados para sintonia do controlador, assim, obtém-se uma ampla gama de possibilidades para cobrir problemas de controle padrão, e para casos específicos pode-se achar uma estratégia mais particular.

3.2.3 Cálculo da lei de controle

A lei de controle é obtida ao resolver o problema de otimização na função custo (3.1), incluindo as restrições, se existirem. O cálculo é feito para cada período de amostragem, utilizando o conceito de janela móvel. Desse modo, aplica-se só a primeira ação de controle e recalcula-se o vetor de incrementos de controle novamente com a informação real do sistema atualizada.

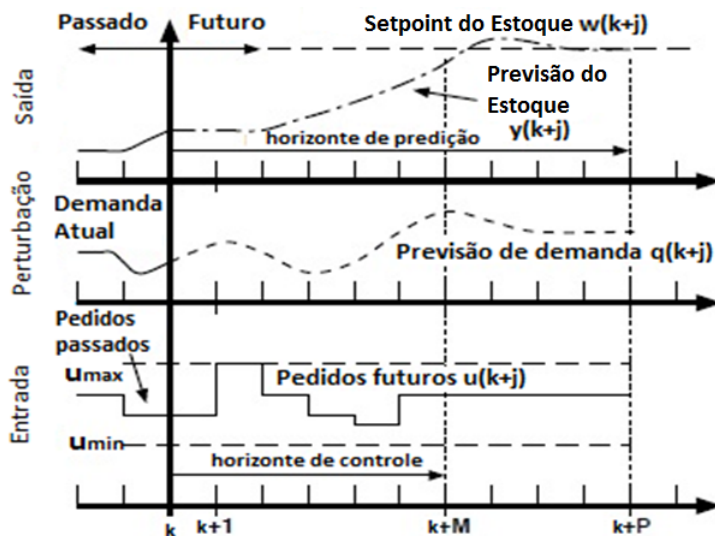
3.2.4 Metodologia dos controladores preditivos

A metodologia dos MPC é caracterizada pela seguinte estratégia:

1. É usado um modelo do processo para prever a saída no futuro a cada amostra (k) e para o horizonte definido (N), chamado horizonte de predição. A saída predita $y_p(k+j | k)$ ¹, depende dos valores conhecidos da entrada e saída no passado até (k), além do valor do controle no futuro $u(k+j-1 | k)$ para $j = 1, 2, 3 \dots N_u$, calculado a partir da otimização da função custo dada.
2. Os sinais de controle futuros são calculados otimizando um critério determinado para manter o processo mais próximo da trajetória de referência $w(k+j | k)$. Normalmente o critério é uma função quadrática do erro de predição e o esforço do controle. Se o critério é quadrático, o modelo linear e não existem restrições é possível obter uma solução explícita, outros casos precisam usar métodos iterativos de otimização.
3. Aplica-se o primeiro elemento do vetor de sinais de controle futuros, ou seja, o sinal de controle correspondente a $u(k | k)$, e fazendo uso do horizonte de janela móvel, a cada amostra calcula-se novamente a sequência de controle ótima incluindo os valores atuais das variáveis no algoritmo.

¹ A notação $y_p(k+j | k)$ indica a predição no instante j à frente de k , calculado com a informação em k .

Figura 3.2 – Metodologia do MPC



Fonte: Elaborado pelo autor

A figura 3.2 exemplifica as características da metodologia do MPC em um sistema de estoque no domínio do tempo. Na parte superior observa-se a saída do sistema (variável controlada) que representa o nível de estoque. No meio, aparece a perturbação do sistema que representa a demanda de produto no estoque. Por último, na parte inferior, observa-se a entrada do sistema (variável manipulada) que descreve as quantidades de produto que devem ser repostas no estoque. Assim, o algoritmo MPC usa o modelo explícito do sistema de armazenamento para fazer as previsões do comportamento no futuro das quantidades de produto em estoque visando atingir um nível desejado (setpoint do estoque). O modelo pode incluir o comportamento da demanda no futuro e, dessa maneira, conhecer melhor as mudanças na estocagem. Otimizando uma função custo são calculadas as ações de controle ótimas, ou seja, são calculadas as quantidades requeridas para atingir a demanda e manter os níveis de estoque desejados. No caso, observam-se limites máximos e mínimos nessas quantidades a serem calculadas, representando restrições no sistema, quantidades que devem ser respeitadas no problema de otimização. Finalmente, como indicado no item 3, as sequências de controle são calculadas ao longo do horizonte, mas só são aplicadas no instante atual

e recalculadas novamente com informação atualizada no seguinte instante de tempo.

3.3 CONTROLE PREDITIVO GENERALIZADO (GPC), SISTEMAS MONO-VARIÁVEIS

Este método utiliza um modelo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*) para a predição da saída do sistema, equação (3.2), a perturbação descrita no polinômio $C(z^{-1})$ é tipicamente modelada como ruído branco integrado.

$$A(z^{-1})y(k) = B(z^{-1})z^{-d}u(k-1) + \frac{C(z^{-1})}{\Delta}e(z^{-1}) \quad (3.2)$$

$$A(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{n_a}z^{-n_a}$$

$$B(z^{-1}) = b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_{n_b}z^{-n_b}$$

$A(z^{-1})$ e $B(z^{-1})$ de ordem n_a e n_b respectivamente, são os polinômios que contêm a dinâmica do sistema. d representa o atraso. É comum $C(z^{-1}) = 1$ para facilitar a análise do algoritmo. Assim, a equação (3.2), pode ser expressada como:

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})}z^{-d}u(k-1) + \frac{1}{A(z^{-1})\Delta}e(z^{-1}). \quad (3.3)$$

Para minimizar a função custo (3.1), é necessário obter primeiro a predição ótima $y_p(k+j|k)$, na janela de predição $N = N_2 - N_1$. Aplicando-se o algoritmo da divisão, o último termo da equação (3.3), se escreve na forma:

$$\frac{1}{A(z^{-1})\Delta} = E_j(z^{-1}) + \frac{F_j(z^{-1})}{A(z^{-1})\Delta}z^{-j} \quad (3.4)$$

Assim, $1 = \Delta A(z^{-1})E_j(z^{-1}) + F_j(z^{-1})z^{-j}$, e fazendo $\hat{A}(z^{-1}) = \Delta A(z^{-1}) = (1 - z^{-1})A(z^{-1})$, obtém-se $\hat{A}(z^{-1})E_j(z^{-1}) = 1 - F_j(z^{-1})z^{-j}$. Dessa maneira, multiplicando a equação (3.2) por $\Delta E_j(z^{-1})z^j$, encontra-se $y_p(k+j|k)$ como se mostra a seguir.

$$\Delta E_j(z^{-1})z^j A(z^{-1})y(k) = \Delta E_j(z^{-1})z^j z^{-d} B(z^{-1})u(k-1) + \frac{\Delta E_j(z^{-1})z^j}{\Delta}e(k)$$

$$\hat{A}(z^{-1})E_j(z^{-1})y_p(k+j|k) = E_j(z^{-1})B(z^{-1})\Delta u(k+j-d-1|k) + E_j(z^{-1})e(k+j|k)$$

$$[1 - F_j(z^{-1})z^{-j}]y_p(k+j|k) = E_j(z^{-1})B(z^{-1})\Delta u(k+j-d-1|k) + E_j(z^{-1})e(k+j|k)$$

$$y_p(k+j|k) = E_j(z^{-1})B(z^{-1})\Delta u(k+j-d-1|k) + E_j(z^{-1})e(k+j|k) + F_j(z^{-1})z^{-j}y_p(k+j|k)$$

Fazendo $G(z^{-1}) = E_j(z^{-1})B(z^{-1})$ resulta:

$$y_p(k+j|k) = G(z^{-1})\Delta u(k+j-d-1|k) + F_j(z^{-1})y_p(k|k) + E_j(z^{-1})e(k+j|k) \quad (3.5)$$

$E_j(z^{-1})$ e $F_j(z^{-1})$ são polinômios auxiliares para o cálculo recursivo das predições, na forma em que os novos valores no passo $j+1$ (E_{j+1} e F_{j+1}) são função do passo j . A melhor predição $y_p(k+j|k)$ obtém-se, supondo que o ruído futuro é nulo $e(k+j|k) = 0$ e como $E_j(z^{-1})$ tem grau menor a j . $E_j(z^{-1})e(k+j|k)$ está no futuro, assim:

$$y_p(k+j|k) = G(z^{-1})\Delta u(k+j-d-1|k) + F_j(z^{-1})y_p(k|k) \quad (3.6)$$

Emprega-se a combinação linear das saídas anteriores do processo e das ações de controle passadas e futuras na janela $N = N_1 - N_2$. O conjunto de N predições ótimas é:

$$\begin{aligned} y_p(k+1|k) &= G_1(z^{-1})\Delta u(k|k) + F_1(z^{-1})y_p(k|k) \\ y_p(k+2|k) &= G_2(z^{-1})\Delta u(k+1|k) + F_2(z^{-1})y_p(k|k) \end{aligned}$$

\vdots

$$y_p(k+N|k) = G_N(z^{-1})\Delta u(k+N-1|k) + F_N(z^{-1})y_p(k|k) \quad (3.7)$$

Cabe esclarecer aqui que, sem perda de generalidade, nos processos que apresentam características de atraso de tempo, os horizontes N_1 e N_2 calculam-se como: $N_1 = d + 1$ e $N_2 = d + N$. A janela de predição é modificada $N = N_2 - N_1$, desse modo só interessam as predições nesse intervalo

assim:

$$y_p(k+d+1|k) = G_{d+1}(z^{-1})\Delta u(k|k) + F_{d+1}(z^{-1})y_p(k|k)$$

$$y_p(k+d+2|k) = G_{d+2}(z^{-1})\Delta u(k+1|k) + F_{d+2}(z^{-1})y_p(k|k)$$

$$\vdots$$

$$y_p(k+d+N|k) = G_{d+N}(z^{-1})\Delta u(k+d+N_u-1) + F_{d+N}(z^{-1})y_p(k|k)$$

A equação (3.7) pode ser reescrita na forma vetorial como:

$$Y = G(z^{-1})\Delta u + F(z^{-1})y_p(k|k) + G'(z^{-1})\Delta u \quad (3.8)$$

onde:

$$Y = \begin{bmatrix} y_p(k+d+1|k) \\ y_p(k+d+2|k) \\ \vdots \\ y_p(k+d+N|k) \end{bmatrix}$$

$$\Delta u = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_u-1) \end{bmatrix}$$

$$G(z^{-1}) = \begin{bmatrix} g_0 & 0 & 0 & 0 \\ g_1 & g_0 & 0 & 0 \\ g_2 & g_1 & g_0 & 0 \\ g_3 & g_2 & g_1 & g_0 \\ \vdots & \vdots & \vdots & \vdots \\ g_{N-1} & g_{N-2} & g_{N-3} & g_{(N-Nu)} \end{bmatrix}$$

$g_0, g_1, g_{(N-1)}$ correspondem aos coeficientes obtidos no calculo das ecuações diofantinas ao longo do horizonte representando a dinâmica do sistema que relaciona as entradas e saídas futuras.

$$G'(z^{-1}) = \begin{bmatrix} z[G_{d+1}(z^{-1}) - g_0] \\ z^2[G_{d+2}(z^{-1}) - g_0 - g_1 z^{-1}] \\ \vdots \\ z^N[G_{d+N}(z^{-1}) - g_0 - g_1 z^{-1} \dots - g_{N_u-1} z^{N_u-1}] \end{bmatrix}$$

$$F(z^{-1}) = \begin{bmatrix} F_{d+1}(z^{-1}) \\ F_{d+2}(z^{-1}) \\ \vdots \\ F_{d+N}(z^{-1}) \end{bmatrix}$$

Os dois últimos termos da equação (3.8) dependem só do passado, por o que podem se agrupar em um só termo f , conforme a equação (3.9).

$$Y = G\Delta u + f \quad (3.9)$$

A equação 3.9 representa uma característica típica dos controladores preditivos, os quais usam os conceitos de resposta livre f e forçada $G\Delta u$ para calcular a ação de controle em função da soma de dois sinais. Em (3.9), G é a matriz com os coeficientes g_i que definem a dinâmica do sistema. f é a resposta livre do sistema, resposta que depende da evolução do processo segundo os controles passados e que no futuro vão se manter constantes. $G\Delta u$ representa a resposta forçada, que é a resposta que depende da evolução do processo segundo os controles futuros.

Usando (3.1)² e colocando ela na forma vetorial temos:

$$J = (Gu + f - W)^T (Gu + f - W) + \Delta u^T \lambda \Delta u \quad (3.10)$$

$$W = \begin{bmatrix} w(k) \\ w(k+1) \\ \vdots \\ w(k+N-1) \end{bmatrix}$$


Fatorando (3.10) como

$$J = u^T G^T Gu + u^T G^T (f - W) + (f - W)^T Gu + (f - W)^T (f - W) u^T + \Delta u^T \lambda \Delta u$$

obtém-se:

²No caso monovariável é possível omitir o parâmetro α na função custo.

Figura 3.3 – Resposta livre



Fonte: Elaborado pelo autor

$$J = \Delta u^T (G^T G + \lambda I) \Delta u + 2(f - W)^T G \Delta u - (f - W)^T (f - W). \quad (3.11)$$


É possível escrever J na forma de uma função quadrática como em (3.12),

$$J = \frac{1}{2} \Delta u^T H \Delta u + b^T \Delta u + f_0 \quad (3.12)$$

Com: $H = (G^T G + \lambda I)$, $b^T = 2(f - W)^T G$ e $f_0 = (f - W)^T (f - W)$. Para um caso sem restrições, a equação (3.12) tem um valor mínimo que se obtém derivando a função em relação à variável Δu e igualando-a a zero, ou seja:

$$\frac{dJ}{du} = H \Delta u + b = 0$$

Figura 3.4 – Resposta Forçada



Fonte: Elaborado pelo autor

Portanto, no caso sem restrições

$$\Delta u = -H^{-1}b = -[2(G^T G + \lambda I)]^{-1}(2(f - W)^T G^T)^T$$

$$\Delta u = (G^T G + \lambda I)^{-1} G^T (W - f) \quad (3.13)$$

Para um sistema sem restrições e devido a que no instante j só interessa aplicar o primeiro elemento de controle $u(k)$, na equação 3.13 só interessa a primeira linha da matriz $(G^T G + \lambda I)^{-1} G^T$. Assim, a lei de controle para o GPC é expressa como:

$$\Delta u = K(W - F), \quad (3.14)$$

K é a primeira linha de $(G^T G + \lambda I)^{-1} G^T$.

3.4 USO DE RESTRIÇÕES

Uma das vantagens mais significativas e interessantes do MPC é a possibilidade de manipular as restrições físicas ou econômicas dos proces-

sos, considerando limites de operação e condições de qualidade específicas. O cálculo da ação de controle descrito na equação (3.13) foi formulado considerando que todos os sinais do processo possuem uma faixa de valores ilimitados. Essa abordagem não é muito realista porque na prática todos os processos estão sujeitos a restrições. Os sinais de controle possuem um intervalo de ação e uma taxa de variação limitada. Razões construtivas e/ou de segurança, causam limitações nas variáveis de processo, como no caso dos níveis nos reservatórios. Os sistemas de controle normalmente operam próximo aos limites, o que pode acarretar violação de restrição. Cabe ao controlador antecipar e corrigir essas violações de forma que não aconteçam, evitando a instabilização do sistema. Neste contexto, os controladores MPC se mostram eficazes, uma vez que possuem a capacidade de prever possíveis violações ao longo do horizonte de predição e incluem as restrições na solução do problema de otimização. Essas características possibilitam que os controladores MPC evitem a ocorrência das mesmas.

No sistema podem ser inseridas restrições *hard* (duras) e *soft* (suaves). As restrições duras são restrições que sempre devem ser cumpridas e estão em maior número associadas às variáveis manipuladas, aplicam-se às variáveis controladas por segurança. Restrições suaves podem ser violadas durante um transitório do sistema causado por perturbações, sendo que em regime permanente devem ser respeitadas.

Existem três tipos principais de restrições frequentemente encontradas em aplicações práticas (CAMACHO; BORDONS, 2004). A otimização da função custo (3.12) considerando restrições é expressada como:

$$J = \frac{1}{2} \Delta u^T H \Delta u + b^T \Delta u + f_0$$

$$\text{Sujeito : } A \Delta u \leq B$$

- *Restrições na variação das variáveis de controle:* Para que existam restrições na taxa de variação da ação de controle no horizonte de controle N_u deve cumprir-se:

$$\Delta u_{min} \leq \Delta u(k) \leq \Delta u_{max}, \quad \forall k$$

pode-se escrever na forma:

$$\begin{aligned}\Delta u(k) &\leq \Delta u_{max} \\ -\Delta u(k) &\leq -\Delta u_{min}\end{aligned}\tag{3.15}$$

Relembrando:

$$\Delta u = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_u-1) \end{bmatrix}$$

É possível expressar as desigualdades (3.15) na forma matricial:

$$\begin{bmatrix} I \\ -I \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_u-1) \end{bmatrix} \leq \begin{bmatrix} \Delta u_{max_1} \\ \Delta u_{max_2} \\ \vdots \\ \Delta u_{max_{N_u}} \\ -\Delta u_{min_1} \\ -\Delta u_{min_2} \\ \vdots \\ -\Delta u_{min_{N_u}} \end{bmatrix}\tag{3.16}$$

- *Restrições na magnitude das variáveis de controle:* quando existem restrições nas magnitudes das variáveis de controle futuras, deve se cumprir:

$$u_{min} \leq u(k) \leq u_{max}, \quad \forall k$$

Ou escritas da forma:

$$\begin{aligned}u(k) &\leq u_{max} \\ -u(k) &\leq -u_{min}\end{aligned}\tag{3.17}$$

As ações de controle futuras, no horizonte de controle N_u , dependem das variações futuras Δu e das ações de controle aplicadas no instante

anterior $u(k-1)$:

$$\begin{bmatrix} u(k) \\ u(k+1) \\ \vdots \\ u(k+N_u-1) \end{bmatrix} = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) + \Delta u(k) \\ \vdots \\ \Delta u(k+N_u-1) + \dots + \Delta u(k) \end{bmatrix} + \begin{bmatrix} u(k-1) \\ u(k-1) \\ \vdots \\ u(k-1) \end{bmatrix}$$

Reordenando a desigualdade (3.17) e escrevendo em forma matricial:

$$\begin{bmatrix} I_t \\ -I_t \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_u-1) \end{bmatrix} \leq \begin{bmatrix} u_{max_1} \\ u_{max_2} \\ \vdots \\ u_{max_{N_u}} \\ -u_{min_1} \\ -u_{min_2} \\ \vdots \\ -u_{min_{N_u}} \end{bmatrix} - \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ -1 \\ -1 \\ \vdots \\ -1 \end{bmatrix} u(k-1) \quad (3.18)$$

$$I_t = \begin{bmatrix} 1 & 0 & \vdots & 0 \\ 1 & 1 & \vdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & \vdots & 1 \end{bmatrix}$$

- *Restrições na magnitude da variáveis de saída* as predições ao longo do horizonte de predição N não podem sobrepassar as restrições nas quais deseja-se que a amplitude da saída se mantenha numa faixa onde os limites correspondem limitações físicas do processo. Essa restrição pode ser:

$$\begin{aligned} y_{min} &\leq y_p \leq y_{max} \\ y_{min} &\leq G\Delta u + f \leq y_{max} \end{aligned}$$

Ou escritas da forma:

$$\begin{aligned} G\Delta u &\leq y_{max} - f \\ -G\Delta u &\leq -y_{min} + f \end{aligned} \quad (3.19)$$

É possível escrever na forma matricial:

$$\begin{bmatrix} G \\ -G \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_u-1) \end{bmatrix} \leq \begin{bmatrix} y_{max_1} \\ y_{max_2} \\ \vdots \\ y_{max_N} \\ -y_{min_1} \\ -y_{min_2} \\ \vdots \\ -y_{min_N} \end{bmatrix} + \begin{bmatrix} -f(k+1) \\ -f(k+2) \\ \vdots \\ -f(k+N) \\ f(k+1) \\ f(k+2) \\ \vdots \\ f(k+N) \end{bmatrix} \quad (3.20)$$

Para trabalhar com restrições *soft* é necessário definir variáveis de folga. O uso de este tipo de restrições pode evitar problemas de factibilidade (quando não existe solução no problema de otimização que consiga satisfazer as restrições duras). A inserção das variáveis de folga em um problema QP pode ser realizada modificando a equação (3.13) de acordo com:

$$\begin{aligned} J &= \frac{1}{2} \Delta u^T H \Delta u + b^T \Delta u + f_0 + \varepsilon^T P \varepsilon + \rho^T \varepsilon \\ \text{Sujeito : } A \Delta u &\leq B + \varepsilon \\ \varepsilon &\geq 0 \end{aligned} \quad (3.21)$$

A constante de ponderação ρ busca penalizar os valores grandes de ε . Ou seja, é mantido em zero sempre que não exista violação de restrições e, é fortemente penalizado quando existe uma violação, obrigando a ε a tomar um valor pequeno o suficiente para evitar o problema de factibilidade. Essa técnica permite inicialmente a violação das restrições e através da minimização da variável de folga, ε . Informações adicionais sobre restrições *soft* podem ser encontradas em (PRASATH; JORGENSEN, 2009).

Para efeitos de simulação, será empregado ao longo do trabalho a estrutura do algoritmo GPC, apresentada na figura 3.5. A estrutura se compõe basicamente por dois blocos, o bloco do otimizador e o bloco do modelo. No bloco do otimizador é calculada a ação de controle ótima, a partir da minimização da função custo, considerando as restrições. No bloco do modelo é calculada a evolução do sistema no futuro (resposta livre). Nos blocos $P(z)$ e $P_q(z)$ descrevem-se a função de transferência do processo e a função de transferência que relaciona o efeito da perturbação na saída respectivamente.

Assim, na equação de predição (3.2) se inclui o efeito da perturbação:

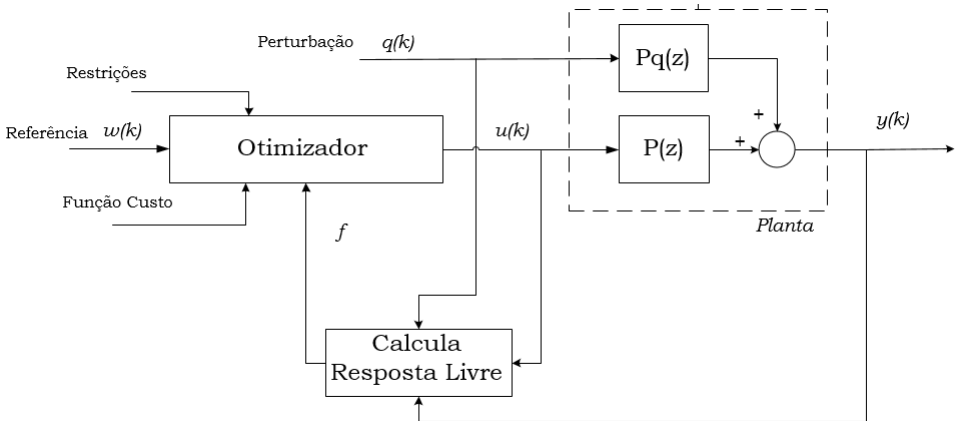
$$A(z^{-1})y(k) = B(z^{-1})z^{-d}u(k-1) + D(z^{-1})z^{-dq}q(k-1) + \frac{C(z^{-1})}{\Delta}e(z^{-1}) \quad (3.22)$$

$$P = \frac{B(z^{-1})}{A(z^{-1})}$$

$$P_q = \frac{D(z^{-1})}{A(z^{-1})}$$

É importante ressaltar, o uso de compensação antecipativa na estrutura ao inserir $P_q(z)$ no cálculo da resposta livre, melhorando o modelo de predição.

Figura 3.5 – Estrutura de controle do GPC



Fonte: Elaborado pelo autor

GPC apresenta problemas em sistema com atrasos e com erros de modelagem. Em trabalhos como (NORMEY-RICO; CAMACHO, 2008a) e (NORMEY-RICO; CAMACHO, 2009), têm-se mostrado que quando se utilizam compensadores de atraso de tempo (DTC) explicitamente na estrutura do GPC se conseguem algumas vantagens sobre o GPC tradicional quando o propósito é estabilidade e robustez em sistemas de controle de processos com atraso de

tempo. Por exemplo, quando se utiliza um preditor de Smith filtrado (FSP) para calcular as previsões até o tempo de atraso ao invés do preditor ótimo inerente ao GPC, o controlador resultante é mais robusto e fácil de ajustar do que a solução tradicional (ROCA et al., 2009). Na seguinte seção são abordados os conceitos principais na utilização do algoritmo DTC-GPC e sua aplicação em sistemas de controle de nível dos estoques.

3.5 GPC PARA SISTEMAS COM ATRASO DE TEMPO (DTC-GPC)

O algoritmo DTC-GPC busca as ações de controle ótimas minimizando uma função custo do tipo (3.1). A previsão da saída do sistema j passos à frente até o instante k $y_p(k+j|k)$ é calculada usando o modelo incremental do sistema, porém feita em duas partes. A primeira parte é o cálculo das previsões até $j+d$ usando a estrutura do FSP, a segunda parte é o cálculo das previsões para $j+d+1$ até $j+d+N_2$ utilizando o procedimento normal do GPC.

Para o cálculo das previsões até $j+d$ tem-se:

$$y_p(k+j|k) = S(z)u(k) + F_r(z)y(k), j = 1 \cdots d \quad (3.23)$$

onde $F_r(z)$ é o parâmetro de ajuste e $S(z)$ deve ser implementado com uma função de transferência estável. No caso, os sistemas de estoque, são modelados com um sistema integrador, dessa maneira, o filtro $F_r(z)$ é definido na equação(3.25).

$$S(z) = G_n(z)[1 - F_r(z)z^{-d}] \quad (3.24)$$

$$F_r(z) = \frac{(f_{b1}z + f_{b0})}{(z - \beta)^2} \quad (3.25)$$

Em (3.24) $G_n(z) = z^{-1}B(z^{-1})/A(z^{-1})$ é o modelo rápido do sistema, ou seja, o modelo livre de atrasos de tempo.

Para dinâmicas do tipo integrador, como são as dinâmicas dos sistemas de estoque: $G_n(z) = \frac{1}{z-1}$. A sintonia do filtro passa-baixas $F_r(z)$ para satisfazer condições de operação frente a perturbações do tipo degrau é descrita na equação (3.25), onde $f_{b0} = (1 - \beta)^2 d + 2(1 - \beta)$, $f_{b1} = (1 - \beta)^2 - f_{b0}$ e β é um parâmetro livre, ajustado utilizando especificações de robustez (SANTOS, 2011). O cálculo de $S(z)$ visando garantir estabilidade interna do preditor, ou seja, visando cancelar internamente ao modelo de previsão o pólo em $z^{-1} = 1$ de $G_n(z)$, se realiza usando as equações (3.26) e (3.27), de forma tal que

$S(z)$ não possua o polo em $z^{-1} = 1$.

$$S(z) = \frac{z^{-d}}{(z-1)} \left[z^d - \frac{(f_{b1}z + f_{b0})}{(z-\beta)^2} \right] \quad (3.26)$$

$$S(z) = \frac{1}{(z-\beta)^2} z^{-d} [z^{d+1} + (1-2\beta)z^d + (1-\beta^2)z^{d-1} + \dots + (1-\beta^2)z + f_{bo}] \quad (3.27)$$

3.5.1 Compensação antecipativa

A ação antecipada na compensação de perturbações mensuráveis apresenta resultados mais eficientes do que o controle realimentado. A principal razão é que ela fornece uma ação de controle antes que a perturbação tenha afetado a variável controlada. De fato, em algumas circunstâncias, é possível rejeitar totalmente o efeito das perturbações de carga a partir da ação antecipativa (GUZMAN; HAGGLUD; VISIOLI, 2012). Desse modo, o controlador inclui os modelos das perturbações e usa também a previsão das perturbações futuras, o que permite incluir o modelo da perturbação na equação de predição, equação (3.2), fazendo o otimizador levar em conta o possível efeito no futuro e calculando uma ação de controle para compensá-lo. Com relação ao DTC-GPC operando com ação antecipativa, além da inclusão do modelo da perturbação no cálculo das predições, deve-se projetar mais um filtro $S_q(z)$ no preditor que corresponde ao filtro de garantia de estabilidade na evolução do comportamento do modelo da perturbação. Assim, o projeto do filtro $S_q(z)$ deve cancelar os modos instáveis da função de transferência que relaciona a perturbação com a saída do processo $P_q(z)$, a fim de garantir estabilidade interna do preditor.

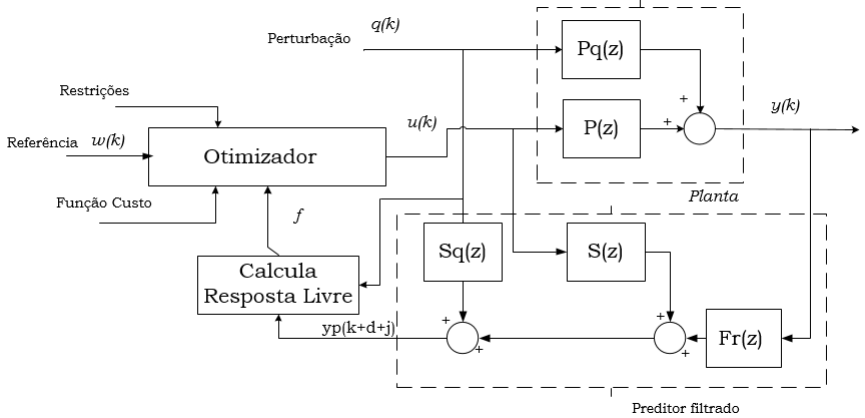
A equação (3.28) formula o cálculo de $S_q(z)$, onde: $G_{nq}(z) = \frac{D(z)}{A(z)}$ é o modelo rápido da função de transferência relativa à perturbação. $F_{qr}(z)$ é o filtro projetado para assegurar uma correta rejeição das perturbações. O parâmetro d_q é o atraso de tempo do modelo $P_q(z)$.

$$S_q(z) = G_{nq}(z)[1 - F_{qr}(z)z^{-d_q}] \quad (3.28)$$

Deve ser comentado que no caso geral, esta solução apenas funciona se os pólos instáveis de $P_q(z)$ são também pólos instáveis de $P(z)$ (RODRÍGUEZ et al., 2016) o que se verifica no modelo do sistema de controle de estoque.

Na figura 3.6 apresenta-se o digrama de blocos que representa a estrutura de controle preditivo DTC-GPC incluindo a ação antecipativa. A estru-

Figura 3.6 – Estrutura do DTC-GPC com ação antecipativa



Fonte: Elaborado pelo autor

tura do algoritmo DTC-GPC se compõe por os três blocos principais. Como no GPC, observam-se o bloco do otimizador e o bloco do modelo e soma-se o bloco do preditor filtrado. No bloco do preditor filtrado é feita a compensação dos atrasos. Os blocos $F_r(z)$, $S(z)$ e $S_q(z)$ descrevem-se os filtros de predição e estabilidade para o modelo da planta e da perturbação respectivamente.

3.6 EXTENSÃO PARA O CASO MULTIVÁRIAVEL

Para trabalhar com sistemas MIMO, deve ser considerada a expressão do processo em função da matriz de transferência $P(z^{-1})$, onde cada elemento $p_{ij}(z^{-1})$ é uma função de transferência SISO sendo $y(k)$ o vetor de variáveis controladas e $u(k)$ o vetor de variáveis manipuladas.

$$y(k) = P(z^{-1})u(k) \quad (3.29)$$

Ou escrito na forma:

$$P(z^{-1}) = D(z^{-1})G(z^{-1}) \quad (3.30)$$

Onde, $D(z^{-1})$ é uma matriz diagonal com os coeficientes de atraso de tempo z^{-d_i} , i é o menor atraso de tempo na linha i de $P(z^{-1})$.

$$p_{ij}(z^{-1}) = \frac{z^{-1}B_{ij}(z^{-1})}{A_{ij}(z^{-1})}z^{-d_{ij}}$$

$G(z^{-1}) = A^{-1}(z^{-1})B(z^{-1})z^{-1}$. $A(z^{-1})$ é uma matriz diagonal que contém os denominadores comuns de todos os denominadores das P_{ij} da linha i e $B(z^{-1})$ é a matriz de numeradores resultantes após a realização do cálculo do denominador comum.

A função custo a otimizar visando o cálculo das ações de controle ótimas é:

$$J(k) = \sum_{i=1}^{N_n} \alpha_i \sum_{j=N_{i_1}}^{N_{i_2}} [y_{pi}(k+j|k) - w_i(k+j|k)]^2 + \sum_{i=1}^{N_m} \lambda_i \sum_{j=1}^{N_{u_j}} [\Delta u_i(k+j-1|k)]^2 \quad (3.31)$$

onde: N_n é o número de variáveis de saída, N_{i_1} e N_{i_2} são os horizontes de predição definidos para cada variável controlada y_{pi} , N_m é o número de variáveis manipuladas e N_{u_j} é o horizonte de controle definido para cada variável manipulada Δu_i . α_i é a matriz diagonal que pondera o erro para cada variável controlada. λ_i contém os valores de ponderação do controle para cada variável manipulada. As predições $y_{pi}(k+j|k)$ são obtidas a partir do modelo definido na equação 3.32, calculadas iterativamente por meio de N_n equações diofantinas, para o horizonte definido.

$$\hat{A}_i(z^{-1})y_{pi}(k+j|k) = z^{-d_i}B_i(z^{-1})u(k+j-1) + \frac{1}{\Delta}e_i(k+j) \quad (3.32)$$

Do mesmo modo que no caso monovariável, assume-se $e_i(k+j|k)$ como ruído branco. $B_i = [B_{i1}, B_{i2}, \dots, B_{im}]$. Assim, a identidade polinomial que permite o cálculo das predições é:

$$1 = \Delta A_i(z^{-1})E_{ij}(z^{-1}) + F_{ij}(z^{-1})z^{-j} \quad (3.33)$$

As predições ótimas são calculadas do mesmo modo que no caso SISO. Desse modo, o processo aqui apresentado permite uma interpretação mais simples dos resultados. Como foi salientado no caso SISO, na equação (3.23), estas predições, a partir de $k = N_{i_1}$ até $k = N_{i_2}$, são usadas na minimização de J , o horizonte mínimo normalmente é escolhido igual ao atraso mínimo, mais um, isto é, $N_{i_1} = d_i + 1$. Aqui o horizonte máximo de cada saída será considerado como o $N_{i_2} = d_i + N_i$. Como no caso SISO, as predições podem ser calculados separadamente, usando a estrutura explícita de compensação de atraso de tempo, a partir de $j = 1$ até $j = d_i$ e de $j = d_i + 1$ a $j = d_i + N_i$ para cada variável controlada.

$$\begin{bmatrix} y_i(k+d_i+1|k) \\ y_i(k+d_i+2|k) \\ \vdots \\ y_i(k+d_i+N_i|k) \end{bmatrix} = [H_{i1} \quad H_{i2} \quad \cdots \quad H_{im}] \begin{bmatrix} u_{f1} \\ u_{f2} \\ \vdots \\ u_{fm} \end{bmatrix} \quad (3.34)$$

$$[H_{pi1} \quad H_{pi2} \quad \cdots \quad H_{pim}] \begin{bmatrix} u_{p1} \\ u_{p2} \\ \vdots \\ u_{pm} \end{bmatrix} + \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_{N_i} \end{bmatrix} \begin{bmatrix} y_i(k+d_i|k) \\ y_i(k+d_i-1|k) \\ \vdots \\ y_i(k+d_i-na_i|k) \end{bmatrix}$$

Aqui as ações de controle futuras são:

$$u_{fj} = [\Delta u_j(k) \quad \Delta u_j(k+1) \quad \cdots \quad \Delta u_j(k-N_{uj})]^T$$

As ações de controle passadas são:

$$u_{pj} = [\Delta u_j(k-1) \quad \Delta u_j(k-2) \quad \cdots \quad \Delta u_j(k-nb_{ij})]^T$$

A matriz S_i tem dimensões $1 \times na_i$, H_{ij} tem dimensões $N_{v_i} \times N_{u_j}$ e H_{pj} tem dimensões $N_{v_i} \times nb_{ij}$. Este procedimento é aplicado a todas as variáveis de saída. Assim, a expressão vetorial é:

$$Y = Hu_f + H_p u_p + S y_d \quad (3.35)$$

Na equação 3.35:

$$Y = [y_1 \quad y_2 \quad \cdots \quad y_n]^T$$

$$u_f = [u_{f1} \quad u_{f2} \quad \cdots \quad u_{fm}]^T$$

$$u_p = [u_{p1} \quad u_{p2} \quad \cdots \quad u_{pm}]^T$$

$$y_d = [y_{d1} \quad y_{d2} \quad \cdots \quad y_{dn}]^T$$

Os elementos de H , H_p e S são números reais. Por causa da interdependência entre as predições com respeito a cada variável, S é uma matriz bloco diagonal, de dimensões $N_i \times na_i$.

Usando as mesmas ideias do caso SISO, escreve-se o problema como a soma de duas partes:

$$Y = Hu_f + f_r \quad (3.36)$$

$f_r = H_p u_p + S y_d$ contém os termos passados, sendo a matriz com a resposta livre dos sistemas, e Hu_f é a resposta forçada. Aplicando o mesmo procedimento que no caso SISO a partir da equação (3.36), resolvendo um problema QP com restrições as predições podem ser calculadas em duas etapas, usando o PSF MIMO para as predições até o tempo morto. Desta forma se obtém um controlador MIMO-DTC-GPC (NORMEY-RICO; CAMACHO, 2007).

No controlador MIMO-DTC-GPC o filtro $F_r(z)$ é um parâmetro de ajuste livre. Note-se que $F_r(z)$ é uma matriz diagonal em função das variáveis controladas do sistema com seus filtros F_{r_i} sintonizados seguindo as idéias de melhorar a robustez ou para lidar com os processos instáveis, assim, o MIMO-DTC-GPC tem duas vantagens importantes: (1) o controlador principal é projetado com considerações de custo ótimas com a possibilidade de considerar as limitações operacionais que permitem um melhor desempenho. (2) A estrutura e ajuste do preditor permite que um controlador mais robusto possa ser obtido. Exemplos de implementação em sistemas MIMO podem ser encontrados em (NORMEY-RICO; CAMACHO, 2007).

3.7 COMENTÁRIOS FINAIS DO CAPÍTULO

Neste capítulo foi realizada uma revisão bibliográfica sobre controle preditivo. Foram apresentados o controlador GPC e a estratégia de controle DTC-GPC que visam tratar os problema de atraso de tempo e incertezas na modelagem. No próximo capítulo serão apresentados os resultados das simulações feitas aplicando os conceitos aqui explicados para uma cadeia de suprimento simples. Também serão introduzidos conceitos de coordenação centralizada e descentralizada na gestão da CS.

4 ESTRATÉGIAS DE CONTROLE

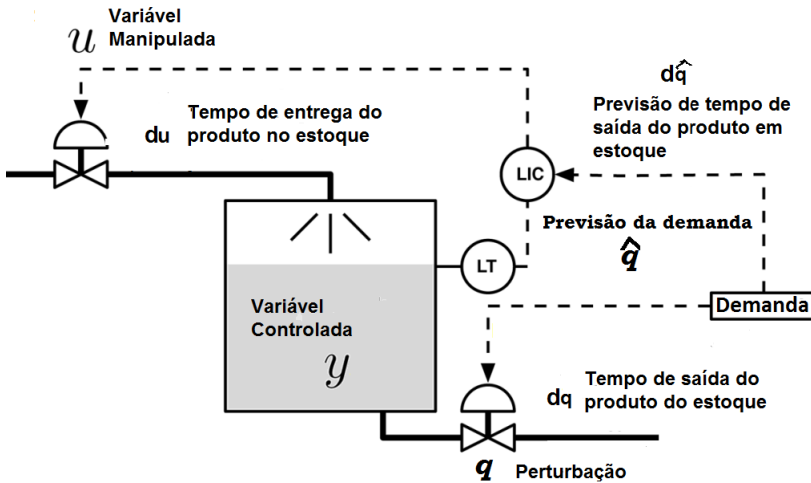
Nos capítulos anteriores foram discutidos assuntos da modelagem dos processos de cadeias de suprimento, técnicas de controle preditivo GPC e modelos utilizados para predição, assim como o aproveitamento da estrutura explícita de compensação de tempo morto no preditor. Este capítulo analisa o uso de controle preditivo com compensação explícita do atraso no controle de estoque em cadeias de suprimento. Serão apresentados os resultados de simulação obtidos nos ensaios da aplicação do GPC para o controle de estoques. A teoria para modelagem apresentada no capítulo 2 foi utilizada para a simulação dos processos. Os mesmos modelos são usados para o cálculo das predições. Foram realizados ensaios primeiramente só para o caso monovariável e posteriormente com o sistema integrado incluindo um sistema multivariável de três entradas e três saídas. Primeiramente são apresentados os ensaios para o caso com comportamento nominal e posteriormente com erros na modelagem, assim como os ensaios para coordenações de gestão centralizada e descentralizada.

4.1 SISTEMA CLÁSSICO DE ESTOQUE

Nesta seção serão apresentados os resultados obtidos nos ensaios de controle de nível do estoque em uma cadeia de suprimentos de um só nó, que tem como objetivo manter o nível de estoque no valor desejado. São apresentados resultados com o controlador GPC para o caso nominal, sistema sem erros de modelagem e com conhecimento *a priori* da demanda futura. Também são mostrados os resultados quando o sistema opera sob erros de modelagem e erros no comportamento da demanda.

A figura 4.1 ilustra as variáveis de controle e representa o sistema de estoque por meio de analogia de fluidos. O sistema de controle de estoque pode se transformar em um sistema de controle de nível. Dessa maneira, é possível resolver o problema com uma malha de controle realimentado. LT: representa o transmissor de nível que indica as quantidades de produto em estoque a cada período de amostragem. LIC: representa o controlador e indicador do nível, aqui o algoritmo resolve a cada instante de amostragem e com a informação atualizada o problema de controle, que define a quantidade de produto que devem se repor no estoque para manter o setpoint.

Figura 4.1 – Analogia de fluidos para um sistema clássico de estoque



Fonte: (SCHWARTZ; RIVERA, 2010)

4.1.1 Resultados do GPC no caso nominal

O primeiro ensaio de controle foi realizado utilizando a estratégia de controle GPC. O sistema de CS possui a dinâmica a seguir: os pedidos feitos à fábrica $u(k)$, têm um tempo de produção e entrega de 5 dias, o que significa um atraso d_u . Após serem entregues, são estocados no depósito, onde são armazenados no estoque $y(k)$. Finalmente os produtos saem do depósito 1 dia depois de serem solicitados, representando um atraso d_q nas quantidades demandadas $q(k)$. O ajuste dos parâmetros do controlador é apresentado na tabela 4.1 e na tabela 4.2 são apresentadas as restrições do sistema. O problema foi simulado utilizando uma referência fixa, visando manter 100 unidades de produto no estoque, $w(k) = 100$.

É usado um horizonte de predição de 30 dias, com o qual consegue-se capturar a dinâmica do sistema e sua evolução nos instantes futuros. O horizonte de controle foi escolhido com 10 dias, dessa maneira o controlador tem tempo suficiente para organizar suas decisões de entrega de uma maneira mais distribuída. Para o fator de ponderação da ação de controle se escolheu o valor de 1, o que permite estudar o comportamento da variável controlada com uma ponderação baixa.

Tabela 4.1 – Parâmetros de ajuste do controlador GPC


Parâmetro	Valor
N	30
N_u	10
λ	1

Tabela 4.2 – Restrições de operação SISO

Parâmetro	Valor
$y_{min} y_{max}$	[0 200]
$u_{min} u_{max}$	[0 100]

São apresentados na figura 4.2 a resposta da variável controlada (quantidade de produto em estoque), as ações da variável manipulada (quantidades de pedidos) e o comportamento da perturbação (demanda). Como é possível apreciar, as quantidades de produto em estoque são mantidas nas proximidades do valor de referência e são rejeitadas as perturbações, ou seja, são atendidas as quantidades demandadas.

Figura 4.2 – Resultados do controlador GPC desconsiderando erros na modelagem e na previsão de demanda




Fonte: Elaborado pelo autor

4.1.2 Resultados do GPC sob incertezas

O segundo ensaio de controle foi realizado para o mesmo sistema de CS. Da mesma maneira, deseja-se manter 100 unidades de produto em estoque. Foi utilizado o controlador GPC sob o mesmo cenário de simulação e as mesmas configurações de ajuste do controlador mencionadas anteriormente. Foi inserido um erro de modelagem de 2 dias no período de fabricação e disponibilidade de produto no estoque. Porém diferenças entre o modelo escolhido para fazer previsões e o comportamento do processo real foram inseridas.

Figura 4.3 – Resultados do controlador GPC considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

Ao realizar as simulações neste caso, a otimização da função custo no algoritmo, não consegue achar o mínimo ótimo que respeite as restrições, gerando um problema de factibilidade. Para efeitos de ilustração, foi realizada uma simulação incluindo uma variável de folga ε para relaxar a restrição nos valores máximo e mínimo da saída. Pode-se observar na figura 4.3 como para ao mesmo ajuste do controlador GPC os erros inseridos deterioram o desempenho do controlador, apesar de inicialmente o controlador tentar manter o nível de estoque programado. Esses resultados evidenciam o que foi anteriormente mencionado no capítulo 3: o algoritmo GPC, apresenta problemas quando controla um processo com tempo morto e incertezas na modelagem,

no caso, características típicas do sistema de CS. Além disso, mesmo com o ajuste da ponderação do controle, não é possível obter um ajuste satisfatório para este caso. Isto confirma os resultados mostrados em (NORMEY-RICO; CAMACHO, 2007) sobre a sintonia do GPC para processos com atraso.

4.1.3 Resultados do DTC-GPC sob incertezas


Com base no exposto anteriormente, é utilizado o algoritmo DTC-GPC sob o mesmo cenário de simulação e os mesmos ajustes de parâmetros do controlador GPC. É adicionada a sintonia do parâmetro β . Este parâmetro é escolhido para projetar os filtros dados pelas equações (3.23), (3.24) e (3.25) para resolver os problemas de estabilidade interna do preditor e fazem mais robusto o controlador frente a atrasos de tempo elevados e com incertezas na modelagem.

Tabela 4.3 – Parâmetros de ajuste do controlador DTC-GPC

Parâmetro	Valor
N	30
N_u	10
λ	1
β	0,95

A simulação do algoritmo DTC-GPC é feita com filtro ajustado de acordo com a tabela 4.3. Assim, a figura 4.4 exhibe os resultados da simulação para o controlador DTC-GPC. Com os resultados da simulação, evidencia-se como é mantida estabilidade das variáveis em comparação com os resultados obtidos com o GPC tradicional; ainda na simulação do algoritmo DTC-GPC não foi inserida a variável de folga ε , devido a que não teve presença de problemas de factibilidade. A resposta mostra como a metodologia de controle preditivo com compensação de tempo morto permite uma melhor solução de problemas em CS que operam sob incertezas na modelagem e na previsão de demanda. Não obstante, o comportamento da variável controlada (quantidades de produto em estoque) apresenta oscilações, assim é possível melhorar o desempenho do controlador estudando uma melhor sintonia dos seus parâmetros.

Figura 4.4 – Resultados do controlador DTC-GPC considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

4.2 EXEMPLO DE CADEIA DE SUPRIMENTOS

Nesta seção serão apresentados os resultados obtidos nos ensaios de controle de nível de estoque em uma cadeia de suprimentos de três camadas. São definidos e testados os tipos de coordenação na cadeia de suprimentos com o fim de comparar desempenhos.

4.2.1 Estruturas de coordenação das cadeias de suprimento

Para coordenação de uma CS deve-se determinar conjuntamente uma estrutura que estabeleça os direitos de decisão, isto é quando produzir e quanto produzir. Essas estruturas de coordenação podem ser de dois tipos: (1) estrutura centralizada ou (2) estrutura descentralizada.

- *Estrutura de Controle Centralizada ou Global:* nesta estrutura é projetado um só controlador para otimizar as quantidades a serem fornecidas a cada dependência da CS, (BOSE; PEKNY, 2000). As decisões são tomadas a partir de dados conhecidos do sistema como uma totalidade (introduzindo a informação global do sistema) buscando atingir um objetivo comum (FU; AGHEZZAF; KEYSER, 2014).

- *Estrutura de Controle Descentralizada ou Local:* nesta estrutura é estabelecido um controlador para cada dependência. Os mercados individuais realizam pedidos para cada unidade de fornecimento baseados no conhecimento e necessidades locais. Cada dependência individualmente não é consciente das limitações e capacidades das outras unidades incluídas na rede, como também desconhece demandas que afetam outros elos do sistema da CS (BOSE; PEKONY, 2000).

4.2.2 Formulação do problema

Nesta seção é considerada uma CS para um só tipo de produto com somente um nó em cada camada, mas o método pode ser estendido para um caso de múltiplos produtos e múltiplos nós. A cadeia de suprimentos tem o seguinte comportamento: a planta tem um tempo de produção de 5 dias e demora 2 dias para transportar o produto semi-acabado após revisões de padrão de qualidade, até a área de embalagem. Na área de embalagem o produto pode demorar até 2 dias dentro do processo de acabamento final e leva-se 1 dia para entregá-lo no depósito. Finalmente, no depósito o produto leva 1 dia no processo de padronização e inclusão no estoque. Os pedidos demoram 1 dia para serem encaminhados após recebidos.

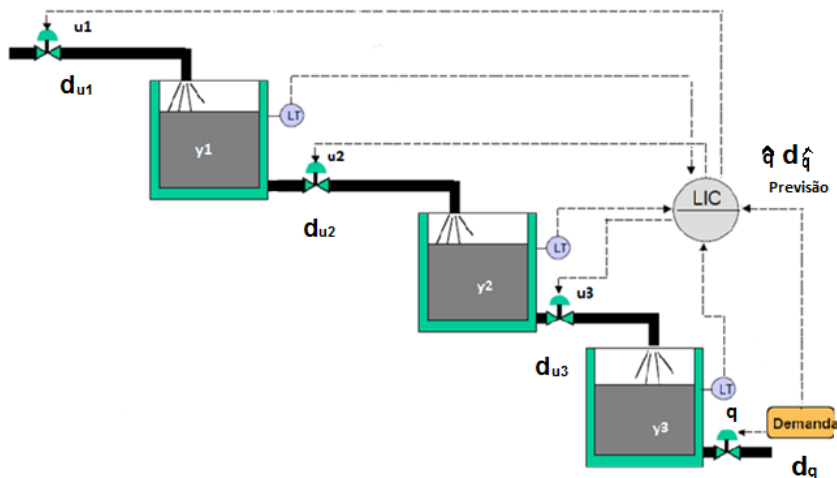
A matriz de transferência que representa as dinâmicas básicas características entre os fluxos de informação e material da CS está dada na equação (4.1). As equações escrevem o modelo de funções de transferência discreta que determinam as quantidades de produto semi-acabado, $y_1(k)$, de produto embalado, $y_2(k)$, e de produto em depósito, $y_3(k)$, como função das variáveis manipuladas (pedidos), $u_1(k)$, $u_2(k)$ e $u_3(k)$, e a perturbações no sistema (efeito da demanda), $q(k)$. As decisões de pedidos e entregas são feitas em iguais períodos de tempo. Escolheu-se um período $T_s = 1$ dia. Considera-se, ainda, que a informação de pedidos entre os elos do processo de produção é feita instantaneamente.

$$\begin{bmatrix} y_1(k) \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} \frac{z^{-1}}{1-z^{-1}} z^{-d_{11}} & \frac{-z^{-1}}{1-z^{-1}} z^{-d_{12}} & 0 \\ 0 & \frac{z^{-1}}{1-z^{-1}} z^{-d_{22}} & \frac{-z^{-1}}{1-z^{-1}} z^{-d_{23}} \\ 0 & 0 & \frac{z^{-1}}{1-z^{-1}} z^{-d_{33}} \end{bmatrix} \begin{bmatrix} u_1(k) \\ u_2(k) \\ u_3(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \frac{-z^{-1}}{1-z^{-1}} z^{-d_q} \end{bmatrix} [q(k)] \quad (4.1)$$

4.2.3 Coordenação centralizada

Os resultados aqui apresentados foram publicados nos anais do "V Congresso Brasileiro de Engenharia de Produção (CONBREPRO 2015)" realizado em Ponta Grossa- Parana . A seguir na figura 4.5, propõe-se uma estratégia de controle centralizada a partir dos modelos dinâmicos apresentados na matriz de transferência, equação (4.1). É projetado um controlador GPC multivariável que usa uma coordenação global para tomar decisões em cada nó da CS. O controlador inclui o modelo da perturbação e usa também a previsão da demanda futura, estimada segundo conhecimentos na tendência do mercado.

Figura 4.5 – Analogia de fluidos na estratégia de controle centralizado.




Fonte: Elaborado pelo autor

4.2.3.1 Resultados do controlador GPC no caso nominal

A seguir serão apresentados os resultados em simulação com o controlador GPC utilizando uma abordagem centralizada a partir dos modelos dinâmicos citados na equação (4.1). Na figura 4.6 mostram-se as variáveis de processo (quantidades de pedidos gerados) e as variáveis de controle (quantidade de produto em estoque) respectivamente. O controlador inclui os mode-

los da perturbação e usa também a previsão da demanda futura. Ainda a figura 4.6 mostra os perfis de demanda utilizados como perturbação nas simulações. Para o caso foram desconsiderados erros na modelagem e no comportamento da demanda.

Figura 4.6 – Resultados de simulação GPC centralizado desconsiderando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

O ajuste de parâmetros dos controladores é apresentado na tabela 4.5 e na tabela 4.4 são definidas as restrições inseridas nas variáveis do sistema no problema de otimização do controlador. Os horizontes de predição foram pensados para olhar até três meses para frente. Escolheu-se 90 dias para o nó de fábrica, 60 dias para o nó de embalagem e 30 dias para o nó correspondente a produto terminado em depósito. Todos os horizontes excedem o total dos tempos mortos ao longo da CS. Para o primeiro nó, abrange-se uma maior quantidade de dias, exigido pela centralização das decisões, a fim de executar antecipações necessárias. A ponderação do esforço de controle, λ_j , foi definida para fixar um controle mais conservador e evitar mudanças violentas nos estoques, reduzindo o efeito chicote (*bullwhip effect*) na CS. Considera-se 600 dias de operação para a cadeia de suprimentos. Nos primeiros 150 dias são inicializados os nós da CS para se manter em um nível fixo de estoque (setpoint), $w_i(k) = 100$ unidades de produto. Para o caso, foram desconsiderados erros na modelagem e no comportamento da demanda.

Tabela 4.4 – Restrições de operação MIMO

Parâmetro	Valor
$y_{i_{min}} y_{i_{max}}$	[0 200]
$u_{j_{min}} u_{j_{max}}$	[0 100]

Tabela 4.5 – Parâmetros de ajuste do controlador GPC centralizado

Parâmetro	Valor
N	[90 60 30]
N_u	[10 10 10]
α_i	[1 1 1]
λ_j	[300 300 100]

Tabela 4.6 – Incertezas inseridas na modelagem

Atraso	Modelo	Processo
d11	5	7
d12	2	2
d22	2	3
d23	1	1
d33	1	2
d3q	1	2


4.2.3.2 Resultados do controlador GPC sob incertezas

A seguir serão apresentados os resultados em simulação com o controlador GPC. Na figura 4.7, são apresentados os resultados de simulação da cadeia de suprimentos operando sob incertezas na modelagem e erros na previsão da demanda. As incertezas de modelagem foram inseridas nos atrasos, levando 2 dias a mais no período de produção, 1 dia a mais dentro do processo de acabado final na área de embalagem e mais 1 dia no processo de padronização e inclusão no estoque do depósito, simulando demoras no processo estabelecido nos tempos de entrega definidos no modelo padrão de operação na CS. Finalmente, foi inserido um erro na previsão da demanda futura, tornando mais realista o comportamento do mercado na CS.

Na tabela 4.6, são resumidos os atrasos do modelo e os atrasos do processo empregados nas simulações, que representam os erros na modela-

gem. Da mesma maneira que no ensaio anterior são empregados os mesmos parâmetros de sintonia no controlador apontados nas tabelas 4.5 e 4.4.

Figura 4.7 – Resultados de simulação GPC centralizado considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

Do mesmo modo que no ensaio monovariável o controlador GPC perde estabilidade ao serem inseridos erros, degenerando o desempenho da CS, apesar de inicialmente o controlador tentar manter os níveis de estoque. Para efeitos de apresentação trabalhou-se com restrições suaves, utilizando a variável de folga ε e modificando a função custo.


4.2.3.3 Resultados do controlador DTC-GPC sob incertezas

Visando corrigir e melhorar os problemas de estabilidade, se aplica na CS o algoritmo DTC-GPC utilizando o mesmo cenário de simulação e as mesmas configurações de ajuste do controlador de acordo com a tabela 4.7. Os β_i usados nos filtros de estabilidade buscam evitar as oscilações da resposta do sistema. A figura 4.8 apresenta o comportamento das variáveis.

Tabela 4.7 – Parâmetros de ajuste do controlador DTC-GPC centralizado

Parâmetro	Valor
N	$[90 \mid 60 \mid 30]$
N_u	$[10 \mid 10 \mid 10]$
α	$[1 \mid 1 \mid 1]$
λ	$[300 \mid 300 \mid 100]$
β	$[0,96 \mid 0,96 \mid 0,96]$

Figura 4.8 – Resultados de simulação DTC-GPC centralizado considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

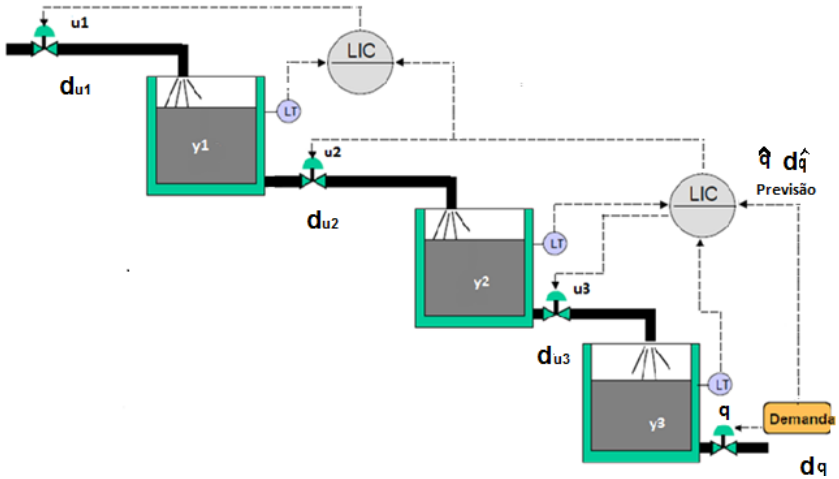
Como se observa na figura, o sistema controlado com o DTC-GPC permite manter os estoques próximo do nível desejado.

4.2.4 Coordenação descentralizada

Foi desenvolvido para o mesmo caso um projeto de controle na abordagem descentralizada, projetando um controlador GPC monovariável para coordenar localmente o estoque de produto semi-acabado $y_1(k)$ o qual devido aos tempos de fabricação apresenta a dinâmica mais lenta. A perturbação é devida aos pedidos que vêm de $u_2(k)$, quantidades requeridas para embla-

gem. Para manter o nível de $y_2(k)$ e o nível de produto em depósito $y_3(k)$ é utilizado um controlador GPC multivariável, para duas entradas - duas saídas, como é apresentado na figura 4.9. Do mesma forma que no projeto centralizado, inclui-se o modelo da perturbação, e emprega-se também a previsão da demanda futura, estimada segundo conhecimentos na tendência do mercado.

Figura 4.9 – Analogia de fluidos na estratégia de controle descentralizado.



Fonte: Elaborado pelo autor

4.2.4.1 Resultados do controlador GPC no caso nominal

A seguir serão apresentados os resultados na abordagem descentralizada dos algoritmos GPC simulados em condições ideais. A figura 4.10 apresenta como os níveis de estoque são mantidos e mostram-se as quantidades de pedidos feitos. Foi empregado o mesmo cenário de simulação das provas feitas na abordagem centralizada, usando os mesmos perfis de demanda e incluindo os mesmos valores nas restrições conforme a tabela 4.4.


O controlador foi ajustado segundo a tabela 4.8. Os horizontes de predição foram escolhidos do modo que excedem o total de atrasos de tempo ao longo da CS: 30 dias para o nó de fábrica, 60 dias para o nó de embalagem e 30 dias para o nó correspondente a produto terminado em depósito. Neste caso, como há dois controladores coordenando a gestão, as variáveis do nó de

fábrica não precisaram usar um horizonte de predição maior. A ponderação do esforço de controle, λ_j , foi diferente da usada no ensaio centralizado. O ajuste foi definido para que os pedidos do nó de fábrica sejam entregues o mais rápido possível. Para os nós de produto em embalagem e em depósito, foram definidas ações de controle mais lentas evitando mudanças violentas nas entregas de produto águas abaixo, reduzindo o efeito chicote (*bullwhip effect*) na CS e evitando zerar o estoque de produto em fábrica.

Tabela 4.8 – Parâmetros de ajuste do controlador GPC descentralizado

Parâmetro	Valor
N	[30 60 30]
N_u	[10 10 10]
α_i	[1 1 1]
λ_j	[1 300 100]

Figura 4.10 – Resultados de simulação GPC descentralizado desconsiderando erros na modelagem e na previsão de demanda




Fonte: Elaborado pelo autor

4.2.4.2 Resultados do controlador GPC sob incertezas

Foi realizado o teste do controlador GPC na presença de erros na modelagem e incertezas na previsão de demanda. Para o ensaio, foram inseridos os mesmos erros de modelagem do caso centralizado (ver tabela 4.6). Na figura 4.11, são apresentados os resultados obtidos na simulação empregando os mesmos parâmetros de sintonia no controlador apontados na tabela 4.8.

Figura 4.11 – Resultados de simulação GPC descentralizado considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

Na figura 4.11 é possível acompanhar como o controlador consegue manter a estabilidade sempre que o atraso não seja elevado, apesar dos erros inseridos. Assim, o controlador GPC projetado para manter os níveis de estoque na área de embalagem e no depósito apresenta um comportamento estável. Por sua vez, o controlador projetado para manter o nível de estoque de produto semi-acabado não consegue manter estabilidade frente aos erros e incertezas na presença de atraso elevado.

4.2.4.3 Resultados do controlador DTC-GPC sob incertezas


Com o objetivo de melhorar estabilidade e garantir a correta operação da CS frente a erros e incertezas, emprega-se o algoritmo DTC-GPC utilizando o mesmo cenário de simulação e as mesmas configurações de ajuste

do controlador de acordo com a tabela 4.9. A figura 4.12 apresentam o resultados da simulação.

Tabela 4.9 – Parâmetros de ajuste do controlador DTC-GPC descentralizado

Parâmetro	Valor
N	[30 60 30]
N_u	[10 10 10]
α	[1 1 1]
λ	[300 100 1]
β	[0.94 0.94 0.94]

Figura 4.12 – Resultados de simulação DTC-GPC descentralizado considerando erros na modelagem e na previsão de demanda



Fonte: Elaborado pelo autor

Há relativamente poucos trabalhos comparando estratégias de coordenação global e estratégias de coordenação local em planejamento de produção (SAHARIDIS; DALLERY; KARAESMEN, 2006). Em geral, uma boa estratégia de coordenação deve trazer benefícios para toda a cadeia de suprimentos. Na prática, no caso de coordenação descentralizada, tende-se a otimizar só uma unidade de produção sujeita a certas limitações (por exemplo, objetivos próprios), com pouca atenção para outros elos da cadeia de abastecimento. Os resultados anteriormente apresentados mostram a diferença entre otimiz-

ção global e local em termos de comportamento dinâmico e desempenho de las variáveis controladas e manipuladas.

É claro que a coordenação centralizada entrega volumes menores de produto do que o caso de coordenação descentralizada. A coordenação descentralizada induz a fábrica a realizar entregas maiores com menor frequência, assim são geradas oscilações nos níveis de estoque. Os exemplos de estudo mostraram, que é melhor implementar uma abordagem global para o gerenciamento de uma cadeia de abastecimento, porque o sistema é capaz de coordenar melhor seus recursos. Isso ocorre porque o coordenador central consegue "ver" todos os possíveis conflitos e restrições no sistema e, em seguida, gerar ações de controle ótimas.

4.3 COMENTÁRIOS FINAIS DO CAPÍTULO

Neste capítulo, foram apresentados os resultados dos ensaios de controle realizados em um primeiro momento para o caso monovariável operando em condições ideais e posteriormente com erros na modelagem e na previsão da demanda. No caso de CS integrada (sistema multivariável), controladores preditivos com compensação explícita de tempo morto considerando estratégias de coordenação centralizada e descentralizada foram propostos para resolver problemas de controle de estoques em uma CS. Os controladores levam em conta restrições a fim de calcular as ações de controle ótimas, considerando as limitações físicas da CS proposta. Quando os sistemas são simulados considerando erros na modelagem e na estimativa da demanda, mostra-se que a estrutura de compensação de tempo morto explícita permite manter estabilidade e um bom desempenho dos controladores, o que não acontece com o GPC em sua estrutura convencional. Os resultados da simulação em geral apresentam um bom seguimento da trajetória de referência (níveis de estoque programados) e uma boa rejeição de perturbações (demanda do mercado). No próximo capítulo serão apresentados os resultados da aplicação dos algoritmos GPC na gestão de CS em estudos de caso na área de petróleo, gás e biocombustíveis.

5 ESTUDOS DE CASO

No capítulo anterior foram apresentados os resultados obtidos com os controladores GPC e DTC-GPC no controle de estoque num sistema simples de CS. No presente capítulo serão apresentados os resultados de simulação para os casos de estudo em petróleo, gás e biocombustíveis.

5.1 ESTUDO EM PETRÓLEO E GÁS

A transformação do petróleo bruto em produtos essenciais para o dia a dia de toda a população é o resultado da soma de muitos esforços para atender à crescente demanda por derivados no Brasil. Parques de refino produzem mais de dois milhões, por dia, de barris de derivados, lubrificantes, entre outras substâncias que servem de matéria prima para diversos outros produtos (PETROBRAS, 2014). O desafio é obter produtos de qualidade, os quais satisfaçam as necessidades dos clientes no que diz respeito ao cumprimento de políticas ambientais e padrões de qualidade dos produtos, sem perder o foco da organização: obter lucros (maximizando a produção, minimizando custos). As refinarias manipulam uma cadeia de suprimentos que implicam entre outros: compra e transporte de matérias primas, operações de refino, armazenamento e distribuição dos produtos finais. A natureza dessa cadeia é tal, que seu estudo econômico é muito complexo e depende de muitas variáveis, como: preços do cru, preço dos produtos e custos operacionais. Nesta seção, a aplicação de controladores GPC e DTC-GPC no controle dos estoques de cru e produtos finais em uma refinaria é proposto, descreve-se o esquema de refino e define-se o sistema de operação da cadeia de suprimento.

5.1.1 Sistema de Refino

O petróleo tal como é extraído, não tem aplicação prática, por isso é necessário separá-lo em diferentes frações que representam utilidade. Este processo é realizado nas refinarias de petróleo. O conjunto de operações realizadas nas refinarias visando obter produtos é chamado de processo de refino, sendo seu principal objetivo obter do cru a maior quantidade possível de produtos. O processo de refino começa com a destilação, o fracionamento do cru em grupos de hidrocarbonetos separados. Os produtos obtidos encontram-se diretamente relacionados com as características do cru processado. A maior parte dos produtos da destilação são convertidos posteriormente em produtos

mais utilizáveis, modificando o tamanho e estrutura das moléculas dos hidrocarbonetos em processos de craqueamento e reforma. Estes produtos são submetidos a vários tratamentos e processos de separação como: extração, hidrotratamento e adoçamento para eliminar componentes indesejáveis e melhorar a qualidade dos produtos (VERRUSCHI et al., 2009).

5.1.2 Formulação do problema

Este estudo centra-se em manter o nível de cru de forma que consiga-se suprir a demanda da refinaria e garantir os níveis dos produtos finais: diesel, gasolina, nafta, gás liquefeito de petróleo (GLP) e querosene de aviação. Para isso é definida uma estrutura de controle descentralizada na qual: são projetados dois controladores. O primeiro controlador é projetado para manter o nível de cru e o segundo controlador é projetado para manter os níveis de estoque nos produtos finais. No sistema estudado assume-se que a informação requisitada (níveis de estoque, volumes demandados e entregues) é comunicada instantaneamente. Além disso, as decisões no sistema de controle são feitas nos mesmos períodos de tempo, dias neste caso de estudo.

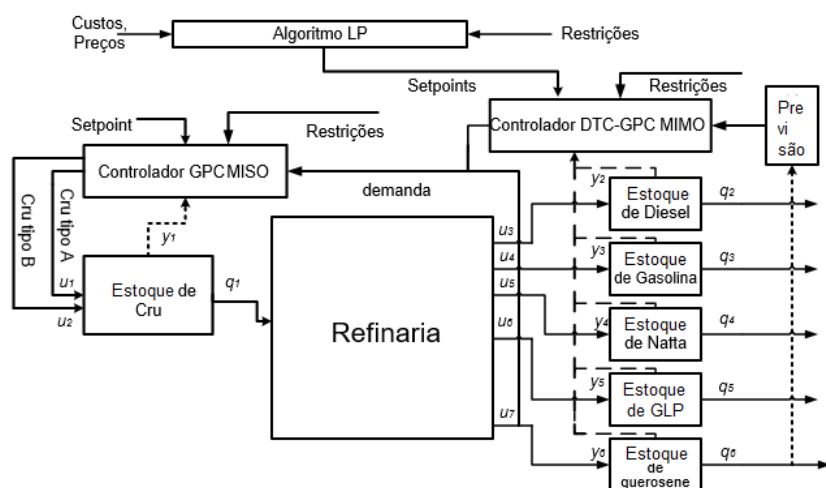
Duas camadas são utilizadas no problema, como mostrado na figura 5.1. A camada superior é resolvida por um algoritmo LP o qual determina os setpoints ideais dos produtos finais. Na simulação é executado a cada 30 dias. Incluiu-se a solução de um problema LP devido a que abordagens tradicionalistas para o planejamento da operação fazem uso de modelos de programação linear, gerando um plano viável em um horizonte diário, semanal, mensal ou anual (SAUL, 2003). Esse processo, apesar de exigir tempo e esforço do programador, gera uma solução viável, que é economicamente atrativa, melhorando a operação da planta (NEIRO; PINTO, 2004). A indústria de petróleo tem incorporado o uso de aplicações computacionais baseadas em LP, visto que essas aplicações permitem obter informação que ajuda na toma de decisões na CS.

Na camada inferior, um controlador GPC é utilizado para manter o nível de estoque de cru. O controlador é chamado de controlador GPC MISO, isto porque o sistema tem duas entradas ou variáveis manipuladas (suprimento do cru tipo A e suprimento do cru tipo B) e uma saída o variável controlada (nível do cru em estoque). Escolheu-se esse controlador porque o modelo de suprimento do cru no estoque das refinarias é bem conhecido e fácil de estimar, e como mostrado no capítulo 4, o algoritmo GPC consegue bons resultados no controle de estoques sob modelos sem incertezas. Para manter os

níveis dos estoques dos produtos finais é utilizado um controlador DTC-GPC multivariável, chamado de controlador DTC-GPC MIMO com 5 variáveis de entrada ou manipuladas (suprimento de diesel, suprimento de gasolina, suprimento de nafta, suprimento de GLP e suprimento de querosene) e 5 variáveis de saída ou controladas (níveis dos produtos em estoque). Embora sejam produtos independentes simplificou-se em um controlador só o controle dos estoques respectivamente e escolheu-se o algoritmo DTC-GPC para contornar possíveis erros nas modelagens por consequência de problemas o atrasos adicionais no processo de refino e produção dos derivados.

As variáveis que aparecem na figura 5.1 e seus significados no ambiente da cadeia de suprimentos estão listadas nas tabelas 5.1 e 5.2.

Figura 5.1 – Esquema de controle descentralizado e mapeamento de variáveis do sistema de CS



Fonte: Elaborado pelo autor

Na camada superior, o problema de programação linear resolve a função custo da equação (5.1). Esta função é definida para maximizar os lucros no problema de LP, sujeitos a restrições de produção e operação, dadas pelas equações (5.2) e (5.3).

Tabela 5.1 – Mapeamento de variáveis no controlador MISO

Variável de processo	Informação na CS
Saída y_1	Quantidade de cru no estoque
Entrada u_1	Quantidade de cru tipo A entregue
Entrada u_2	Quantidade de cru tipo B entregue
Perturbação q_1	Quantidade de cru demandado
Setpoints w_1	Nível de cru programado

Tabela 5.2 – Mapeamento de variáveis no controlador MIMO

Variável de processo	Informação na CS
Saída y_2	Quantidade de diesel no estoque
Saída y_3	Quantidade de gasolina no estoque
Saída y_4	Quantidade de nafta no estoque
Saída y_5	Quantidade de gás liquefeito de petróleo no estoque
Saída y_6	Quantidade de querosene de aviação no estoque
Entrada u_3	Quantidade de diesel entregue
Entrada u_4	Quantidade de gasolina entregue
Entrada u_5	Quantidade de nafta entregue
Entrada u_6	Quantidade de gás liquefeito de petróleo entregue
Entrada u_7	Quantidade de querosene de aviação entregue
Perturbação q_2	Quantidade de diesel demandada
Perturbação q_3	Quantidade de gasolina demandado
Perturbação q_4	Quantidade de nafta demandado
Perturbação q_5	Quantidade de gás liquefeito de petróleo demandada
Perturbação q_6	Quantidade de querosene de aviação demandado
Setpoints w_i	Níveis no estoque programados

$$Z = \max \sum ((S_j - C_j)V_j) \quad (5.1)$$

$$\sum V_j \leq RVT \quad (5.2)$$

$$V_{jT} \leq V_j \leq V_{jC} \quad (5.3)$$

A função objetivo proposta no algoritmo LP é baseada na otimização do uso de recursos do sistema, maximizando os lucros totais. O primeiro termo é responsável pelos preços de venda, onde S_j é o preço unitário para

o produto j . O segundo termo, representa o custo total de produção, assim C_j é o custo geral por unidade de produto j de matéria-prima, transporte e armazenamento. Finalmente, V_j é o volume do produto j que é exigido no tempo de amostra. A restrição de desigualdade linear (5.2) é definida tendo em conta a capacidade total de refino (RVT) e a restrição (5.3) é usada para garantir as quantidades mínimas a produzir para que o processo seja rentável V_{jT} , e ao mesmo tempo, para delimitar V_j na capacidade máxima de refino por dia V_{jC} , em cada tipo de produto j .

Na camada inferior, o modelo do tanque de cru usado nas predições do controlador MISO aparece na equação (5.4) e a matriz de transferência usada no controlador MIMO que inclui os modelos dos tanques dos produtos finais é apresentada na equação (5.5). Os ganhos K_d, K_g, K_n, K_p, K_q representam os fatores de conversão para os tipos de produtos específicos. Os atrasos de tempo d_d, d_g, d_n, d_p, d_q representam o tempo que demora o produto específico para estar disponível em estoque.

$$y_1(k) = \frac{z^{-1}}{1-z^{-1}}(u_1(k-1) + u_2(k-1) - q_1(k)) \quad (5.4)$$

$$\begin{aligned} \begin{bmatrix} y_2(k) \\ y_3(k) \\ y_4(k) \\ y_5(k) \\ y_6(k) \end{bmatrix} &= \begin{bmatrix} K_d \frac{z^{-1}z^{-d_d}}{1-z^{-1}} & 0 & 0 & 0 & 0 \\ 0 & K_g \frac{z^{-1}z^{-d_g}}{1-z^{-1}} & 0 & 0 & 0 \\ 0 & 0 & K_n \frac{z^{-1}z^{-d_n}}{1-z^{-1}} & 0 & 0 \\ 0 & 0 & 0 & K_p \frac{z^{-1}z^{-d_p}}{1-z^{-1}} & 0 \\ 0 & 0 & 0 & 0 & K_q \frac{z^{-1}z^{-d_q}}{1-z^{-1}} \end{bmatrix} \begin{bmatrix} u_3(k) \\ u_4(k) \\ u_5(k) \\ u_6(k) \\ u_7(k) \end{bmatrix} \\ &+ \begin{bmatrix} \frac{-z^{-1}}{1-z^{-1}} & 0 & 0 & 0 & 0 \\ 0 & \frac{-z^{-1}}{1-z^{-1}} & 0 & 0 & 0 \\ 0 & 0 & \frac{-z^{-1}}{1-z^{-1}} & 0 & 0 \\ 0 & 0 & 0 & \frac{-z^{-1}}{1-z^{-1}} & 0 \\ 0 & 0 & 0 & 0 & \frac{-z^{-1}}{1-z^{-1}} \end{bmatrix} \begin{bmatrix} q_2(k) \\ q_3(k) \\ q_4(k) \\ q_5(k) \\ q_6(k) \end{bmatrix} \end{aligned} \quad (5.5)$$

No caso do controlador MISO, na função custo foi acrescentado um termo de penalidade econômica, com o fim de regular os fluxos de cru. Assim, baseado no estudo de (SOUZA, 2007) e (PORFIRIO, 2011), é focado o desenvolvimento de um algoritmo de integração de fatores econômicos e ca-

racterísticas do desempenho do controle. Para isso, é considerada uma função objetivo econômica associada ao estado estacionário das previsões y_{pi} .

Para o estado estacionário, procura-se o ponto onde o valor ótimo de $u(k)$ seja o valor mínimo de $u(k) = u(k-1) + \Delta u(k)$ ao longo do horizonte. Na equação (5.7) é apresentada a função custo utilizada no caso MISO.

$$J(k) = \sum_{j=N_1}^{N_2} \alpha [y_p(k+j|k) - w(k+j|k)]^2 + \sum_{m=1}^{N_m} \lambda_m \left(\sum_{j=1}^{N_u} [\Delta u_m(k+j-1|k)]^2 \right. \\ \left. + \delta_m \sum_{j=1}^{N_u} [\Delta u_m(k+j-1|k) + u_m(k+j-1|k-1)]^2 \right) \quad (5.6)$$

Na forma matricial do algoritmo de otimização quadrática QP chega-se a:

$$J = \Delta u^T (G^T \alpha G + \lambda I + \delta I) \Delta u + 2((f - W)^T \alpha G + u(k-1)^T \delta) \Delta u \quad (5.7)$$

onde, δ define a importância da otimização econômica com relação aos erros da variável controlada. O uso do termo econômico, neste caso, permite restringir e limitar o uso do cru, segundo o preço. A vantagem dessa integração dentro dum mesmo algoritmo consiste no maior sincronismo entre as ações de controle em função de que o problema dinâmico e econômico estão sendo considerando em um mesmo algoritmo.

No caso do controlador MIMO trabalhou-se com a função custo tradicional do GPC, nela são corrigidos os erros de modelagem e são ponderados os esforços de controle.

5.1.3 Resultados de simulação

O estudo de caso considera 180 dias de simulação da cadeia de suprimentos. O sistema é inicializado com os dados apresentados na tabela 5.4 e opera segundo estes até a primeira ordem do algoritmo de LP, o qual indica os novos setpoints como os níveis ótimos calculados. O sistema é simulado sob incertezas na previsão da demanda e erros na modelagem.

No caso dos perfis de demanda, foram pressupostos dados de consumo usualmente utilizados nos sistemas produtivos. Na prática esses dados são estimados e calculados com ajuda de ferramentas informáticas empre-

Tabela 5.3 – Dados de simulação do algoritmo LP

Produto	Lucro [US/ m^3]	Quantidades mínimas [m^3]
Diesel	[6, 12 53, 78]	3000
Gasolina	[116, 19 60, 89]	12000
Nafta	[83, 96 140, 23]	3000
Gás liquefeito	[8, 75 105, 71]	2000
Querosene	[34, 97 16, 85]	1000
Produção Total [m^3 /dia]		36000

Tabela 5.4 – Dados de simulação e estados iniciais na CS

Parâmetro	Valor [m^3]
Setpoint e cru no estoque	40000
Setpoint e diesel no estoque	5000
Setpoint e gasolina no estoque	16000
Setpoint e nafta no estoque	7000
Setpoint e gás liquefeito no estoque	5000
Setpoint e querosene no estoque	3000

sariais baseadas em informações de produção, custos e vendas. Por exemplo, com a informação para os mesmos períodos de tempo em anos anteriores são realizadas projeções do consumo no período atual. Com tal característica, simulou-se um perfil de demanda conhecido (valores de consumo para cada dia) e foi inserido no modelo de predição. Da mesma maneira, foi inserido um perfil de demanda próximo do programado somando uma incerteza aleatória do tipo ruído branco simulando a demanda do mercado real.

Nos modelos foram inseridos erros nos tempos de entrega do produto disponível em estoque, simulando falhas na operação da refinaria. Os dados empregados nos cálculos do algoritmo LP encontram-se na tabela 5.3, assim como na tabela 5.5 são apresentados os atrasos correspondentes ao modelo e ao processo.

Na tabela 5.6 são apresentados os parâmetros da sintonia do controlador GPC MISO. O horizonte de predição foi escolhido com o fim de acompanhar com informação suficiente as demandas da refinaria. As ações de con-

Tabela 5.5 – Incertezas inseridas na modelagem controlador DTC-GPC MIMO

Atraso	Modelo	Processo
d_d	2	4
d_g	2	3
d_n	1	2
d_p	2	3
d_q	1	2

trole foram suavizadas usando um fator de ponderação igual a 10. Isso para evitar o possível efeito chicote na variável controlada, devido a mudanças repentinas na entrada e saída de cru. A ponderação do termo econômico foi condicionada ao preço de compra do cru, o petróleo tipo A é um cru leve, porém mais caro; o petróleo tipo B, é um cru mais pesado, com um preço muito mais baixo no mercado.

Tabela 5.6 – Parâmetros de ajuste do controlador MISO

Parâmetro	Valor
N	30
Nu	[10 10]
α_i	1
λ_m	[10 10]
δ_m	[120 80]

No caso do controlador DTC-GPC MIMO a tabela 5.7 apresenta os parâmetros empregados na configuração do controlador. Foram escolhidos horizontes de controle e predição mais curtos, porém suficientes para atingir os objetivos e foram suavizadas as ações de controle igual que no caso do controlador GPC MISO visando diminuir problemas por efeito chicote. Para contornar o problema com os erros na modelagem nos tempo de entrega e a operação com erros na previsão de demanda, foram escolhidos os parâmetros β_i . Valores de restrição nos estoques e quantidades entregues estão listados nas tabelas 5.8 e 5.9.

Na figura 5.2 se aprecia a resposta do controlador MISO. O nível de estoque programado é mantido, e o controlador consegue rejeitar a perturbação gerada pela demanda. E importante ressaltar como o objetivo da função

Tabela 5.7 – Parâmetros de ajuste do controlador MIMO

Parâmetro	Valor
N	[15 15 15 15 15]
Nu	[5 5 5 5 5]
α_i	[1 1 1 1 1]
λ_j	[10 10 10 10 10]
β_i	[0,88 0,86 0,86 0,85 0,85]

Tabela 5.8 – Parâmetros de restrição controlador MISO

Parâmetro	Valor [m^3]
$y_{1min} y_{1max}$	[0 50000]
$u_{1min} u_{1max}$	[0 20000]
$u_{2min} u_{2max}$	[0 20000]


Tabela 5.9 – Parâmetros de restrição controlador MIMO

Parâmetro	Valor [m^3]
$y_{imin} y_{imax}$	[0 20000]
$u_{jmin} u_{jmax}$	[0 10000]

custo com a inclusão do termo econômico, faz com que seja utilizado em menor quantidade o petróleo tipo A que representa um custo mais elevado.


Nas figuras 5.3 a 5.7 é possível observar as respostas do controlador MIMO. Os níveis dos estoques buscam acompanhar o setpoint respectivo indicado pela camada de otimização superior e o sistema em malha fechada rejeita as perturbações geradas pelas demandas respectivas de produto. Apesar de ter respostas lentas nos transitórios o sistema consegue contornar os problemas de incertezas e erro na modelagem, mantendo estabilidade nas variáveis controladas.

Figura 5.2 – Estoque de cru




Fonte: Elaborado pelo autor

Figura 5.3 – Estoque de diesel




Fonte: Elaborado pelo autor

Figura 5.4 – Estoque de gasolina




Fonte: Elaborado pelo autor

Figura 5.5 – Estoque de nafta




Fonte: Elaborado pelo autor

Figura 5.6 – Estoque de gás liquefeito de petróleo



Fonte: Elaborado pelo autor

Figura 5.7 – Estoque de querosene de aviação



Fonte: Elaborado por o autor

5.2 ESTUDO EM BIOCOMBUSTÍVEIS

A indústria de biomassa tornou-se uma importante área de estudos em cadeias de suprimento devido ao crescimento explosivo gerado pelos regulamentos ambientais e necessidades de energia renováveis. Além disso, o comportamento dinâmico típico de cadeia de fornecimento justifica o interesse em técnicas MPC. Há diversos estudos que propõem algoritmos MPC, a fim de melhorar o desempenho dos sistemas de CS na indústria de biocombustíveis (AN; WILHELM; SEARCY, 2011). Nestes estudos os autores analisam como realizar a integração dos níveis de decisão a fim de gerar impacto no desempenho geral do sistema. Nesta seção, a aplicação de um controlador DTC-GPC no controle do estoque de biomassa em uma usina brasileira é proposto, descreve-se o esquema de produção na indústria de cana de açúcar e define-se o sistema de operação da cadeia de suprimento.

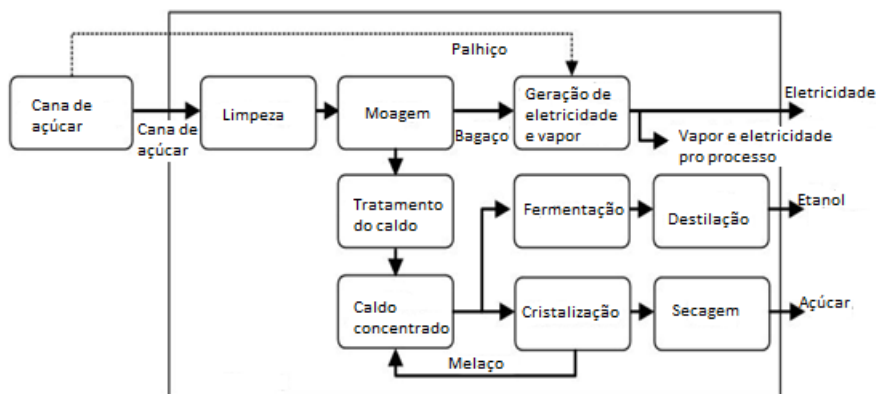
5.2.1 Esquema de sustentabilidade

O processamento de cana no Brasil é feito através de uma cadeia de produção muito integrada. Açúcar e etanol são produzidos combinado com um sistema de co-geração para suprir a demanda energética necessária, trabalhando como um processo de produção autônoma (PERAN et al., 2011). A Figura 5.8 mostra o diagrama de fluxo, com os fluxos principais e saídas da planta que são: o açúcar, o etanol, e potência.

Os passos típicos para produção em grande escala de açúcar são: moagem, tratamento de caldo, cristalização e secagem. No processo de moagem, caldo de cana e bagaço é produzido. O caldo é tratado quimicamente, a fim de manter as propriedades e parâmetros de qualidade; cristalização e secagem termina o processo de transformação do açúcar. O caldo também alimenta os processos de fermentação e destilação para produção de etanol. Resíduos (bagaço da moagem e, palhiço) são usados para produzir energia (vapor e eletricidade) necessária para a planta operar; o excedente de energia elétrica é vendida à rede, aumentando os lucros do processo (PERAN et al., 2011). Este estudo centra-se em manter os níveis de biomassa nos valores ideais, necessários para garantir uma produção ótima de açúcar, etanol e eletricidade. A ideia de controle é determinar as quantidades ideais de cana e bagaço tendo em conta as exigências do mercado.

No sistema estudado assume-se que a informação requisitada é comunicada instantaneamente. Além disso, as medidas e decisões no sistema

Figura 5.8 – Fluxo de processos de açúcar, etanol e bio-electricidade



Fonte: Elaborado pelo autor

de controle são feitas nos mesmos períodos de tempo, dias para este caso de estudo. Todas as variáveis e seus significados no ambiente da cadeia de suprimentos estão listadas na tabela 5.10 .

5.2.2 Formulação do problema

Para uma organização que trabalha com biomassa, o negócio é geralmente baseado em um plano mensal de pré-venda. O planejamento da produção pode ser escalado em dias para definir as taxas de processamento de produtos (MENENGUETTI, 2014).

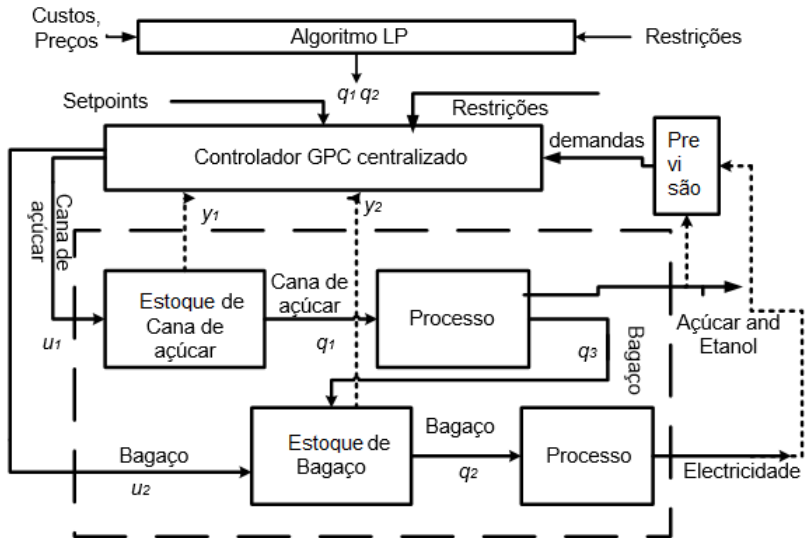
O planejamento de produção nas usinas brasileiras é basicamente desenvolvido para cumprir com contratos pré-assinados de açúcar e etanol. Ao mesmo tempo, o processo de geração de eletricidade deve servir quantidades contratuais, além de fornecer o próprio consumo de energia, evitando os custos adicionais de compra de energia de terceiros (AL-OTHAM et al., 2007).

Todo o processo é um sistema de duas entradas e duas saídas, com três distúrbios, como descrito na matriz de transferência apresentada em (5.8). Os ganhos K_b , K_p , K_A e K_E da função de transferência da perturbação representam os fatores de conversão de tipos de produtos específicos, a variável d_b , representa o atraso de tempo que tem o bagaço comprado de terceiros para estar disponível no estoque.

$$\begin{bmatrix} y_1(k) \\ y_2(k) \end{bmatrix} = \begin{bmatrix} \frac{z^{-1}}{1-z^{-1}} & 0 \\ 0 & \frac{z^{-1}}{1-z^{-1}} z^{-d_b} \end{bmatrix} \begin{bmatrix} u_1(k) \\ u_2(k) \end{bmatrix} + \begin{bmatrix} \frac{(-k_A + k_E)z^{-1}}{1-z^{-1}} & 0 & 0 \\ 0 & \frac{-K_P z^{-1}}{1-z^{-1}} & \frac{k_B z^{-1}}{1-z^{-1}} \end{bmatrix} [q(k)] \quad (5.8)$$

Duas camadas são utilizadas no problema, a parte superior é resolvida por um algoritmo de LP e um controlador DTC-GPC multivariável é utilizado no nível inferior, para contornar problemas de erro na modelagem, quando existirem diferenças nos tempos de entrega do bagaço comprado de terceiros. Para o controle propõe-se uma estratégia centralizada, como mostrado na figura 5.9. Assume-se que todas as instalações são de propriedade da mesma empresa, a informação é compartilhada pela rede. Portanto, um sistema de controle centralizado é adequado e viável. Toda a informação disponível é fornecida ao controlador e as decisões de fornecimento (quantidades) são determinados pelo coordenador global (FU; AGHEZZAF; KEYSER, 2014).

Figura 5.9 – Esquema de controle centralizado e mapeamento de variáveis do sistema de CS



Fonte: Elaborado pelo autor

Tabela 5.10 – Mapeamento de variáveis no controlador

Variável de processo	Informação na CS
Saída y_1	Quantidade de cana de açúcar no estoque
Saída y_2	Quantidade de bagaço no estoque
Entrada u_1	Quantidade de cana de açúcar entregue
Entrada u_2	Quantidade de bagaço entregue
Perturbação q_1	Quantidade de cana de açúcar demandada
Perturbação q_2	Quantidade de bagaço demandado
Perturbação q_3	Quantidade de bagaço subproduto da moagem
Setpoints w_i	Níveis de estoque programados

A solução do problema LP define, indiretamente, as demandas de bagaço e cana de açúcar para o processo, que são os principais distúrbios no sistema de controle do nível de estoque. A função objetivo, equação (5.9), é definida para maximizar os lucros, sujeitos a restrições de produção e operação, equações (5.10) e (5.11).

$$Z = \max \sum ((S_j - C_j)V_j) \quad (5.9)$$

$$\sum V_j \leq PVT \quad (5.10)$$

$$V_{jT} \leq V_j \leq V_{jC} \quad (5.11)$$

A função objetivo proposta é baseada na otimização do uso de recursos do sistema, maximizando os lucros totais. O primeiro termo, é responsável pelos preços de venda, onde S_j é o preço unitário para o produto j . O segundo termo, representa o custo total de produção, assim C_j é o custo geral por unidade de produto j de matéria-prima, transporte e armazenamento. Finalmente, V_j é o volume do produto j que é exigido no tempo de amostra.

A restrição de desigualdade linear (5.10) é definida levando em conta a capacidade total de produção da planta (PVT) e a restrição (5.11) é usada para garantir a entrega das quantidades mínimas contratadas V_{jT} , e ao mesmo tempo, para delimitar v_j na capacidade máxima de processamento V_{jC} , em cada tipo de produto j .

5.2.3 Resultados de simulação

O estudo de caso considera 360 dias de simulação da cadeia de suprimentos e como a safra de cana de açúcar é limitada, a entrega de cana de açúcar é suspensa por um período de 60 dias. As demandas do mercado otimizadas resolvendo o problema LP em (5.9) são consideradas como as demandas geradas para o controlador DTC-GPC MIMO. A flexibilidade para ajustar os parâmetros do controlador para satisfazer o desempenho exigido é considerada neste exemplo de simulação na definição dos horizontes de predição $N_1 = [1|1]$ até $N_2 = [60|60]$ (dias) e dos horizontes de controle $Nu = [10|10]$ (dias), ver tabela 5.11. Os horizontes longos são exigidos visando ter informação suficiente e ajudar nas decisões centralizadas, a fim de executar antecipações necessárias. O problema de gestão da CS pode ainda se beneficiar da aplicação do DTC-GPC em outros aspectos, por exemplo, mantendo o estoque desejado, acompanhando as demandas dos clientes e reduzindo o efeito chicote. Este último aspecto é tratado com a penalização do controle λ_j , usadas para moderar as quantidade de bagaço entregue, com o fim de diminuir os custos de compra de terceiros e aproveitar ao máximo o bagaço subproduto da moagem. Além disso, serão obtidas menores flutuações nos níveis de estoque. São considerados erros na modelagem nos tempos de entrega de bagaço comprado de terceiros e para isso foi sintonizado o filtro com o parâmetro β_i para manter a estabilidade no nível de bagaço.

Tabela 5.11 – Parâmetros de ajuste do controlador

Parâmetro	Valor
N	[60 60]
Nu	[10 10]
α_i	[1 1]
λ_j	[1 10]
β_i	[0,85 0,96]

O modelo do sistema é inicializado utilizando os parâmetros apontados na tabela 5.12 (unidades em toneladas [t]). O fornecimento do bagaço inicialmente é zero, trabalhando unicamente com bagaço subproduto do processo de transformação da cana.

Tabela 5.12 – Dados de simulação e estados iniciais na CS

Parâmetro	Valor [t]
Quantidades nos estoques	[5000 5000]
Setpoints	[5000 5000]
Quantidades de cana de açúcar entregue	3000
Quantidade de bagaço entregue	0
Quantidade de cana de açúcar demandada	6200
Quantidade de bagaço demandado	2000

Tabela 5.13 – Parâmetros de restrição


Parâmetro	Valor [t]
$y_{i_{min}} y_{i_{max}}$	[0 10000]
$u_{1_{min}} u_{1_{max}}$	[0 10000]
$u_{2_{min}} u_{2_{max}}$	[0 10000]

Valores de restrição nos estoques e quantidades entregues estão listados na tabela 5.13. As restrições são impostas na simulação numérica de modo que a simulação da cadeia de suprimentos representa um sistema o mais próximo possível em condições reais de operação.

O controlador minimiza o desvio nas posições dos estoques de seus setpoints. Note-se que as posições de estoque só podem permanecer dentro dos limites $y_{i_{min}} | y_{i_{max}}$ devido a limitações de capacidade físicas. As restrições sobre as quantidades de produto a serem entregues são definidas com base nos limites de capacidade de transporte $u_{i_{min}} | u_{i_{max}}$.


Os níveis de estoque são mostrados nas figura 5.10 (superior), e 5.12 (superior). As quantidades de produto entregue são apresentadas nas figuras 5.10 (inferior) e 5.12 (inferior). É claro que é possível manter os níveis de estoque, mostrando pequenas flutuações quando acontecem mudanças na demanda. Neste caso, as quantidades de bagaço que são entregues externamente estão penalizadas, já que o objetivo é maximizar a utilização de resíduos de processo, ver figura 5.12. No período no qual a safra acaba, é possível observar como o bagaço comprado de terceiros, aumenta as entregas para suprir a demanda.

Figura 5.10 – Estoque cana de açúcar



Fonte: Elaborado pelo autor


Figura 5.11 – Cana de açúcar demandada



Fonte: Elaborado pelo autor


Os resultados nas figura 5.11 e 5.13 mostram as quantidades demandadas específicas por tipo de produto. É claro como o algoritmo de programação linear LP define as quantidades necessárias de cana-de-açúcar para serem processadas e cumprir com a produção exigida de açúcar e de etanol. Em relação à demanda de potência, o algoritmo garante as quantidades de energia utilizadas para sustentar o processo. A abordagem de programação linear usa a capacidade de geração máxima para atender a contratos de exportação de energia e, quando possível, produz mais energia para vender na rede.

Figura 5.12 – Nível de estoque de cana de açúcar



Fonte: Elaborado pelo autor

Figura 5.13 – Bagaço demandado



Fonte: Elaborado pelo autor

5.3 COMENTÁRIOS FINAIS DO CAPÍTULO

Neste capítulo, foram apresentados os resultados de simulação em dois estudos de caso na área de petróleo, gás e biocombustíveis. Controladores preditivos multivariáveis nas abordagens centralizada e descentralizada são aplicados para resolver o problema de controle de estoque nas cadeias de suprimento especificadas, trabalhando em um esquema de duas camadas com

um algoritmo de LP que comanda as políticas de CS para melhorar os lucros. Os resultados obtidos mostram que o controlador DTC-GPC MIMO pode ter um impacto significativo e positivo sobre o controle dos níveis de estoque e, ao mesmo tempo, satisfazer as demandas do mercado gerada pelo algoritmo de LP. Parâmetros de ajuste desempenham um papel importante na obtenção do desempenho desejado para as operações da cadeia de fornecimento. Tem sido ilustrado nas simulações que esta estratégia de controle pode ser sintonizada segundo requisitos de desempenho. Bons resultados são observados porque a implementação do GPC centralizado tem pleno conhecimento de modelos e fluxos de informação do sistema, o que lhe permite coordenar as decisões tomadas por cada nó da CS. O controlador olha os níveis de inventário estratégicos necessários para satisfazer as demandas de pico e mantém estoques dentro dos níveis de segurança desejados em períodos de baixa demanda. É importante mencionar, contudo, que a qualidade da gestão depende em grande parte a qualidade dos dados de predição. Os resultados globais das simulações mostram bom acompanhamento de referência e boa rejeição de distúrbios.

6 CONCLUSÕES

Este trabalho abordou o estudo do controle de processos que envolvem cadeias de suprimentos tipicamente caracterizados como processos com atraso de tempo elevado e dinâmicas integradoras. Foram desenvolvidas duas estratégias de controle, sendo a primeira baseada no controlador preditivo generalizado, conhecido como GPC, e a segunda baseada em uma modificação da forma de realizar predições no algoritmo GPC conhecida como DTC-GPC. O GPC difere de outros controladores preditivos pelo fato de utilizar o modelo em função de transferência para realizar as predições, o que foi interessante nos casos tratados ao longo do trabalho por possuírem modelos simples claramente representados por funções de transferência. Além disso, a capacidade de tratar restrições de forma explícita no cálculo do controle foi aproveitada para tratar as limitações físicas e as restrições operacionais dos processos considerados. Adicionalmente, algumas ferramentas como a estrutura de compensação antecipativa foram empregadas com a finalidade de melhorar o tratamento das perturbações.

Foram realizados ensaios de simulação visando avaliar o desempenho dos controladores com o sistema operando sob incertezas na previsão da demanda e erros na modelagem. Os resultados obtidos foram comparados nas duas estratégias de controle implementadas, mostrando as vantagens em termos de estabilidade da estratégia DTC-GPC. Verificou-se nos ensaios que o controlador GPC sempre que não operava sob grandes atrasos de tempo obteve bons resultados. As principais contribuições deste trabalho são:

- aplicação de controles preditivos do tipo GPC ao controle de uma cadeia de suprimento de três camadas, um só nó por camada e para um único produto;
- aproveitamento da estrutura explícita de compensação de atraso do tempo da abordagem DTC-GPC para aplicação em cadeias de suprimento;
- uso da técnica de compensação antecipativa da demanda em CS;
- ensaios nas abordagens centralizada e descentralizada.

Com relação à utilização dos controladores GPC nos estudos de caso em petróleo, gás e biocombustíveis, apresentaram-se bons resultados nas diferentes configurações propostas, tornando-os grandes candidatos na aplicação no meio industrial. Esses tipos de ferramentas tornam-se de crucial

importância para o pessoal especializado em logística e operações nas empresas, uma vez que permitem operação ótima do sistema dadas as informações disponíveis em dado instante de tempo. A implementação do controlador GPC se mostra inovadora, uma vez que esses tipos de algoritmo é facilmente embutido em pacotes de software, basta fazer a comunicação do algoritmo GPC com o sistema gerencial, que tipicamente possuem dados já disponíveis e em tempo real dos estoques, taxas de produção, previsões de vendas e outras informações, que ajudam na tomada de decisões e implementação de estratégias para a gestão de estoques.

Uma grande contribuição deste trabalho é a inclusão do termo adicional de penalização econômica na função custo, o qual teve por objetivo administrar o suprimento de dois tipos de cru baseado no preço de compra. Indicando um uso moderado para um petróleo mais caro, priorizando o uso do petróleo mais barato. Dessa forma, foi provado com êxito como é possível por médio do MPC incluir decisões nos suprimentos de petróleo em função de manter níveis de estoque, satisfazendo condições econômicas. Como contribuição para o estudo de controle preditivo em cadeias de suprimento, este trabalho gerou as seguintes publicações:

- Álvarez, D. and Normey-Rico, J. and Flesch, R. "Controle preditivo para cadeias de suprimentos sujeitas a incertezas de modelagem e de previsão de demanda". *V congresso de Engenharia de produção, CON-BREPRO*, 2015, Ponta Grossa - Parana.
- Álvarez, D. and Normey-Rico, J. and Flesch, R. "Model Predictive Control for Inventory Management in Biomass Manufacturing Supply Chains", *International Journal of Production Research*, 2016. (Submetido)

6.1 SUGESTÕES PARA TRABALHOS FUTUROS

Os sistemas de cadeias de suprimento estudados neste trabalho representam somente uma parte das múltiplas topologias existentes. Existe muito trabalho a ser realizado na área de gestão de CS usando controladores preditivos. Pensando nisso, são sugeridos possíveis temas de pesquisa a serem realizados futuramente com o objetivo de estudar melhor o comportamento dos sistemas de controle de estoque em cadeias de suprimento, simulá-los em ambiente computacional e estudar técnicas de controle eficientes:

- testar o desempenho do controlador GPC perante a um sistema de cadeia de suprimentos com produção e armazenagem de vários produtos, ou

seja, um sistema de maior complexidade que envolva vários nós por camada;

- substituir o uso do algoritmo de programação linear e empregar técnicas de otimização multi-objetivo nas quais os algoritmos GPC otimizem tanto as variáveis de processo na camada inferior, quanto as variáveis de rendimento econômicas na camada superior.

REFERÊNCIAS

AL-OTHAM, W. et al. Supply chain optimization of petroleum organization under uncertainty in market demands and prices. **European Journal of Operational Research**, v. 189, p. 822–840, 2007.

ALVAREZ, D.; NORMEY-RICO, J.; FLESCHE, R. Controle preditivo para cadeias de suprimentos sujeitas a incertezas de modelagem e de previsão de demanda. In: . Ponta Grossa: V Congresso Brasileiro de Engenharia de Produção, 2015.

AMERICANO, M. **Modeling, Control and Optimization of ethanol industry process: an application in solar energy**. Tese (Doutorado) — Federal University of Santa Catarina, Florianópolis, 2013.

AN, H.; WILHELM, W.; SEARCY, S. Biofuel and petroleum-based fuel supply chain research: A literature review. **Biomass and Bioenergy**, v. 35, p. 3763–3774, 2011.

BEAMON, B. Supply chain design and analysis: Models and methods. **Internacional Journal of Production Economics**, v. 55, p. 281–294, 1998.

BENET, E.; SUBIAS, A.; GRIÑÓ, R. **Descripción y análisis de los trabajos existentes sobre el efecto "bullwhip" y su tratamiento con técnicas de teoría de control**. Catalunya: Universitat Politècnica de Catalunya. Institut d'Organització i Control de Sistemes Industrials, 2006.

BERNHARD, J.; MARIOS, C. System dynamics modelling in supply chain management: research review. In: . Uxbridge Middlesex: Winter simulation Conference, 2000.

BOSE, S.; PEKNY, J. A model predictive framework for planning and scheduling problems: a case of consumer goods supply chain. **Computers and Chemical Engineering**, v. 24, p. 329–335, 2000.

BRAUM, M. et al. Application of model predictive control to robust management of multi-echelon demand networks in semiconductor manufacturing. In: . Tempe Arizona: International Conference on Modeling and Analysis of Semiconductor Manufacturing, 2002.

CAMACHO, E.; BORDONS, C. **Model Predictive Control**. London: Springer, 2004.

CLARKE, D.; MOHTADI, C.; TUFFS, P. Generalized predictive control — part i. the basic algorithm. **Automatica**, v. 23, p. 137–148, 1987.

CNI; DIRET; IBP. A contribuição do setor brasileiro de petróleo, gás e biocombustíveis para o desenvolvimento sustentável no país. In: . Rio de Janeiro: Conferência Rio+20, 2012. CNI: Confederação nacional da indústria, DIRET: Diretoria de educação e tecnologia, IBP: Instituto brasileiro de petróleo gás e bioconbustíveis.

EICHMANN, D. Creating a high-performance downstream petroleum supply chain. **Achieving Supply Chain Excellence through Tecnology**, p. 229–232, 2000.

FU, D.; AGHEZZAF, E.; KEYSER, R. A model predictive control framework for centralised management of a supply chain dynamical system. **Systems Science and Control Engineering: An Open Access Journal**, v. 2, p. 250–260, 2014.

GAGLIARDO, A.; CORSANO, G. A multiperiod milp model for the design of a bioethanol supply chaing considering sustainability. **Iberoamerican Jorunal of Industrial Engiennering**, v. 3, p. 209–225, 2011.

GARCIA, C.; MORSHEDI, A. Quadratic programming solution of dynamic matrix control. **Chemical Engiennering Communications**, v. 46, p. 73–87, 1985.

GARCIA, C.; PRETT, D.; MORARI, M. Model predictive control: Theory and practice—a survey. **Automatica**, v. 25, p. 335–348, 1989.

GUZMAN, J.; HAGGLUD, T.; VISIOLI, A. **PID control in the thrird millennium**. London: Springer, 2012.

HERBET, S. On the application of servomechanism theory in the study of production control. **Econometrica**, v. 20, p. 247–680, 1952.

KAPSIOTIS, D.; TZAFESTAS, S. Decision making for inventory production planning using model-based predictive control. **Parallel and distributed computing in engineering systems**, p. 551–600, 1992.

LI, X.; MARLIN, T. Robust supply chain performance via model predictive control. **Computers and Chemical Engineering**, v. 33, p. 2134–2143, 2009.

MENENGUETTI, S. **Sustainability report communication on proccess, Santa Terezinha Power Plant**. Paraná, 2014. Disponível em:

<https://www.usacucar.com.br/verPdf.php?arq=99>. Acesso em 15 de Novembro de 2015.

MIN, H.; ZHOU, G. Supply chain modeling: past, present and future. **Computer and Engineering**, v. 43, p. 231–249, 2002.

NANDOLA, N.; RIVERA, D. An improved formulation of hybrid model predictive control with application to production-inventory systems. **IEEE Transactions on Control Systems Technology**, v. 21, p. 121–135, 2013.

NEIRO, S.; PINTO, J. A general modeling framework for the operational planning of petroleum supply chain. **Computer and Chemical Engineering**, v. 28, p. 871–896, 2004.

NORMEY-RICO, J.; CAMACHO, E. **Control of Dead-time Processes**. London: Springer, 2007.

NORMEY-RICO, J.; CAMACHO, F. Dead-time compensators: A survey. **Control Engineering Practice**, v. 16, p. 407–428, 2008a.

NORMEY-RICO, J.; CAMACHO, F. Unified approach for robust dead-time compensator design. **Journal of Process Control**, v. 19, p. 38–47, 2009.

OPEC. **Annual Statistical Bulletin, OPEC: Organization of the Petroleum Exporting Countries**. Vienna, 2013.

PACHECO, E. **Usando dinâmica de sistemas para análise de algoritmos de reposição de estoque em ambientes produtivos**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Paraná, Curitiba, 2004.

PERAN, J. et al. **White book of Automation and Control on Sugarcane industry**. España: Iberoamericam program of science and technology for development: CYTED, 2011.

PEREA, E.; YDSTIE, B.; GROSSMANN, I. A model predictive control strategy for supply chain optimization. **Computers and Chemical Engineering**, v. 27, p. 1201–1218, 2003.

PETROBRAS. **Expandendo os Limites**. 2014. Disponível em: <http://www.petrobras.com/pt/energia-e-tecnologia/tecnologia-e-pesquisa/expandindo-os-limites/>. Acesso em 08 de Dezembro de 2014.

PIN-HO, L.; SHAN-HILL, D.; JANG, S. Controller design and reduction of bullwhip for a model supply chain system using z-transform analysis. **Journal of Process Control**, v. 14, p. 487–499, 2004.

PORFIRIO, C. **Implantação de otimizador online acoplado ao controle preditivo (MPC) de uma coluna de Tolueno**. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

PRASATH, G.; JORGENSEN, J. Soft constraints for robust mpc of uncertain systems. **International Symposium on Advanced Control of Chemical Processes**, v. 7, 2009.

PWC. **A indústria brasileira de petróleo e gás, PWC: PricewaterhouseCoopers. Ltda.** Brasil, 2014. Disponível em: <http://www.pwc.com.br/pt/publicacoes/setores-atividade/assets/oil-gas/oeg-tsp-14-port.pdf>. Acesso em 09 de Dezembro de 2015.

RICHALET, J. et al. Model predictive heuristic control: Applications to industrial processes. **Automatica**, v. 14, p. 413–428, 1978.

ROCA, L. et al. Robust constrained predictive feedback linearization controller in a solar desalination plant collector field. **Control Engiennenring Practice**, v. 17, p. 1076–1088, 2009.

RODRÍGUEZ, C. et al. On the filtered smith predictor with feedforward compensation. **Journal of Process Control**, v. 41, p. 35–46, 2016.

SAHARIDIS, G.; DALLERY, Y.; KARAESMEN, F. Centralized versus decentralized production planning. **RAIRO Operations Reserach**, v. 40, 2006.

SANTOS, T. M. **Contribuições para o controle preditivo com compensação de atraso robusta**. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, 2011.

SARIMVEIS, H. et al. Dynamic modeling and control of supply chain systems: A review. **Computers and Research**, v. 35, p. 3530–3561, 2007.

SAUL, I. **Linear programing methods and applications**. Massachusetts: Ser. Dover books on Computer Science Series, Courier Corporation, 2003.

SCHWARTZ, J.; RIVERA, D. A process control approach to tactical inventory in production-inventory systems. **Int.J. Production Economics**, v. 125, p. 111–124, 2010.

SIMCHI-LEVI, D.; KAMINSKY, P.; SIMCHI-LEVI, E. **Managing the Supply Chain**. New York: McGraw-Hill, 2004.

SOUZA, G. **Integração da Otimização em Tempo Real com Controle Preditivo**. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, São Paulo, Brasil, 2007.

SUBRAMANIAM, K. et al. Integration of control theory and scheduling methods for supply chain management. **Computer and Chemical Engineering**, v. 51, p. 4–20, 2012.

TERUMICHI, R. **Modelagem Sistêmica e Planejamento Logístico da Cadeia de Suprimentos de Petróleo**. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo, São Paulo, Brasil, 2007.

TOWILL D.AND NAIM, M.; WIKNER, J. Industrial dynamics simulation models in the desing of supply chains. **International Journal of Physical Distribution and Logistics Management**, v. 22, p. 3–13, 1992.

VALLADARES, F. **Um estudo comparativo de políticas de gestão de estoques utilizando técnicas de controle**. Dissertação (Mestrado) — Escola Politécnica, Universidade Federal de Rio de Janeiro, Rio de Janeiro, 2014.

VASSIAN, J. Application of discrete variable servo theory to inventory control. **Operations Research**, v. 3, p. 272–821, 1955.

VERRUSCHI, E. et al. Como planificar óptimamente la cadena de suministros de una refinería de petróleo. **Universidad, Ciencia y Tecnologia**, v. 13, p. 339–344, 2009.

WANG, J. A supply chain application of fuzzy set theory to inventory control models – drp system analysis. **Expert Systems with Applications**, v. 36, p. 9229–9239, 2009.

WANG, W.; RIVERA, D.; KEMPF, K. Centralized model predictive control strategies for inventory management in semiconductor manufacturing supply chains. In: . Denver Colorado: American Control Conference, 2003.